

3-0: تمهيد

تعتبر الطرق الإستكشافية الإبتدائية ذات فائدہ في فهم الطبيعة المعقدة لعلاقة المتغيرات المتعددة . ويعتبر اسلوب فحص البيانات من اجل التوصل الى هيكل للتجمعات "الطبيعة" من الأساليب الإستكشافية الهامة فهي تساعدنا في تحديد الأبعاد والتعرف على القيم الشاذة بالإضافة الى اقتراح روابط او فروض تصف العلاقة بين المتغيرات.

لا يضع تحليل التجميع أي فروض تخص عدد المجموعات أو هيكلها مما يجعله اسلوب بدائي لوصف التجمعات . وتم عملية التجميع بناء على أوجه التمايز أو الاختلاف وتعد مقاييس التمايز أو البيانات في حساب التمايز مدخلات لإسلوب تحليل التجميع.

كثيراً ما نهتم بتجمیع عدد من الوحدات في مجموعات متباينة داخلياً في ضوء مشاهدات ذات بعد P مأخوذة من هذه الوحدات في المتغيرات x_1, x_2, \dots, x_p مثلاً تجمیع أشخاص حسب قراءات أخذت منهم إلى مجموعات قد تمثل أجناس أو أعراف مختلفة . كذلك قد يهمنا تجمیع عدد من المتغيرات في مجموعات قد ترتبط المتغيرات في كل منها بعامل معین.

3-1 المبحث الأول: مقاييس البيانات الرقمية Measures for numerical data

الهدف الأساسي من تحليل التجميع هو اكتشاف التجمعات الطبيعية للمفردات أو المتغيرات لذا يجب علينا ان نتوصل أولاً الى مقياس كمي لقياس التوافق "التماثل" بين المفردات.

في أغلب الأحيان يمكننا تجمیع المفردات بمجرد النظر في اشكال انتشارها "ذات بعدين او ثلاثة" وذلك على الرغم من عدم وجود تعريف دقيق لمفهوم التجمیع الطبيعي .

وللإستفاده من المقدرة العقلية على تجمیع الأشياء المشابهه فقد تم التوصل حديثاً الى اسالیب بيانيه عديده لرسم المشاهدات ذات الأبعاد المتعددة في بعدين فقط.

1-1-3: المسافة Distance

عند محاولة تجمیع وحدات لابد أن يكون لدينا أولاً مقياس للمسافة بين أي وحدتين مثلًا A و B. وهناك عدة مقاييس للمسافة منها ، المسافة الإقليدية Euclidian Distance والإنحراف Mahalanobis Distance وهو مربع المسافة الإقليدية ومقاييس مهالونبس للمسافة Deviance

والمتوسطة Average Distance. فكبير المسافة يشير إلى وجود عدد كبير من الأزواج غير المتماثلة.¹

وفيما يلي نتناول هذه المقاييس بایجاز :

3-1-2: المسافة الأقلبية Euclidean Distance

المسافة الاقليدية معروفة لنا جميعاً فإذا نظرنا إلى النقطة $(x_1, x_2) = P$ في المستوى فإنها وفقاً لنظرية فيثاغورث يمكن إيجاد المسافة الخطية بينها وبين نقطة الأصل $(0,0)$ = 0 ويرمز لهذه المسافة بالرمز $d(0, P)$ كما يلى:

وعموماً إذا كان لدينا نقطة في فراغ ذي p من الأبعاد ، أي إذا كان لدينا النقطة $p = (x_1, x_2, \dots, x_p)$ فإن المسافة بينها وبين نقطة الأصل $(0,0,\dots,0) = 0$ هي :

$$d(0, p) = (\sqrt{x_1^2 + x_2^2 + \dots + x_p^2})$$

ويمكن تعميم هذا المفهوم لقياس المسافة بين وحدتين A و B فإذا كانت X_A و X_B مشاهدات ذات بعد P (في P متغير) على الوحدتين A و B فإن المسافة الإقليدية بينهما تعرف:²

3-1-3 الانحراف Deviance

يعرف الانحراف للمسافة بين وحدتين A و B كما يلى:

^١. ريشلر جونسون ، ديرن وشن ، التحليل الإحصائي للمتغيرات المتعددة من الوجهة التطبيقية ، تعریف . عبدالمرضي حامد عزام - دار المريخ للنشر ، المملكة العربية السعودية - 1418هـ - 1998م. ص (855).

²- عزة احمد - تجميم مستشفىات ولابة الخرطوم - بحث تكميل، لتبil درجة الماجستير في الاحصاء -جامعة النيلين - يناير 2009م ص(11)

$$(\underline{X}_A - \underline{X}_B)' (\underline{X}_A - \underline{X}_B) = ^3\text{الإنحراف}(3-3)$$

أي أنه مربع المسافة الإقليدية.

4-1-3: مسافة مهالانوبس Mahalanobis Distance

يتم إيجاد هذه المسافة عن طريق العلاقة :

$$d_{mah} = \sqrt{(X - Y)\Sigma^{-1}(X - Y)'}(4-3)$$

⁴ هي عبارة عن مصفوفة التباينات والتغيرات.

5-1-3: المسافة القصوى Maximum Distance

ويطلق على هذه المسافة أيضاً المسافة الجزئية (sup distance) إذ نجد أقصى مسافة بين المتغيرات فمثلاً إذا كان لدينا المتغيرين X, Y في d من الأبعاد المسافة القصوى بينهما توجد كما يلى:

$$d_{max}(x, y) = \max_{1 \leq k \leq d} |x_j - y_j|(5-3)$$

6-1-3: مسافة منكوفסקי Minkowski Distance

المسافة الإقليدية ومسافة مانهاتن والمسافة القصوى عبارة عن ثلاثة حالات خاصة من مسافة منكوف斯基 وهذه المسافة تعرف بـ :

$$d_{min}(x, y) = \left(\sum_{j=1}^d |x_j - y_j|^r \right)^{\frac{1}{r}}, r \geq 1(6-3)$$

عندما :

3-عزه أحمد - مرجع سابق ص(12)

⁴ - ملرتن تي ويلز - وأخرون - تجميع البيانات - سلسلة إصدارات الجمعية الأمريكية الأمريكية (فرجينيا) - جمعية الصناعات والتطبيقات الرياضية (بنسلفانيا) - الولايات المتحدة الأمريكية - سبتمبر 2007م. ص(72)

⁵ - ملرتن تي ويلز - وأخرون - مرجع سابق ص (72)

$r = 1, 2$ and ∞

تُنتج المسافة الإقليدية مسافة مانهاتن والمسافة القصوى على التوالى.

3-1-7: المسافة المتوسطة Average Distance:

هذه المسافة يمكن إيجادها من المسافة الإقليدية كالتالي:

أفرض أن لدينا المتغيرين y, x ذات بعد d المسافة المتوسطة تصبح⁶:

⁶ - مارتن تي ويلز - وأخرون - مرجع سابق ص (74)

3-2 طرق التجميع والدمج Clustering Method and Amalgamation

وفي هذا المبحث سنتناول بإيجاز المفاهيم الأساسية المرتبطة بتجميع وحدات في ضوء مشاهدات $X' = [x_1, x_2, \dots, x_p]$ مأخوذة منها.

توجد ثلاثة طرق مختلفة يمكن استخدامها لعنقoda أو تجميع البيانات وهي:

1- التحليل العنقودي بواسطة الـ K متوسط : يستخدم عند معرفة عدد العناقيد المطلوبة حيث تدخل قبل اجراء التحليل.

2- التحليل العنقودي الهرمي: يستخدم عندما يكون عدد البيانات صغير.

3- التحليل العنقودي ذو الخطوتين : يستخدم عندما يكون عدد البيانات كبير جداً أو عندما تكون البيانات مختلطة ما بين المتغيرات المتصلة والمتغيرات الوصفية.

وسوف يقتصر الباحث على التحليل العنقودي الهرمي والتحليل العنقودي بواسطة الـ K متوسط.


3-2-1 الدمج Amalgamation:

متلما تتطلب عملية التجميع تحديد مقياس للمسافة تحتاج أيضاً لتحديد طريقة لدمج العناقيد. وهناك ثلاثة طرق للدمج هي طريقة الربط المفرد وطريقة الربط الكامل وطريقة الربط المتوسط والتي يتم تناولها بإيجاز كما يلي:

3-2-2 طريقة الربط المفرد:

- تعتبر واحدة من أسهل طرق التحليل العنقودي - عرفت بواسطة فلوريك Florek (1951) والربط المفرد يعرف بعدة تعريفات منها الجار الأقرب ، طريقة الحد الأدنى توظف أقرب الجارين لدراسة او قياس الاختلاف بين مجموعتين، ويظهر كما مبين:

الشكل(1-3) الربط المفرد



المصدر : اعداد الدارس باستخدام برنامج MS-Word

في هذه الحالة ومن الشكل (1-3) يمكن ان نفترض ان a هي اقرب وحدة في المجموعة الاولى
إلى المجموعة الثانية و b هي اقرب وحدة في المجموعة الثانية إلى المجموعة الاولى عليه اعتماد
المسافة بين a و b لقياس الاختلاف بين المجموعتين يسمى الربط المنفرد

والصيغة الرياضية لهذه الطريقة تكون كما يلي:

أفرض أن لدينا $C_i, C_k \& C_j$ عبارة عن ثلاثة مجموعات فالمسافة D بين C_k و $C_i \cup C_j$ يمكن الحصول عليها من صيغة لانس - ويليامز Lance - Williams كالتالي⁷:

$$\begin{aligned} & D(C_k, C_i \cup C_j) \\ &= \frac{1}{2}D(C_k, C_i) + \frac{1}{2}D(C_k, C_j) - \frac{1}{2}|D(C_k, C_i) - D(C_k, C_j)| \\ &= \min\{D(C_k, C_i), D(C_k, C_j)\} \dots \dots \dots (8-3) \end{aligned}$$

3-2-3: طريقة الربط الكامل Complete Link Method

هذه الطريقة أكثر حذراً إذ تعتبر المسافة بين أي مجموعتين هي المسافة بين أبعد وحدتين

فيهما كما يلي:

الشكل(2-3) الربط الكامل⁸

⁷ - مارتن تي ويلز وأخرون- تجميع البيانات - مرجع سابق ص (118)

⁸ - د. ريتشارد جونسون ، ديرن وشن، مرجع سابق ص (866)



المصدر : اعداد الدارس باستخدام برنامج MS-Word

فلنفرض ان a هي ابعد وحدة في المجموعة الاولى من المجموعة الثانية و b هي ابعد وحدة في المجموعة الثانية من المجموعة الاولى عليه يتم استخدام هاتين الوحدتين لقياس الاختلاف بين المجموعتين.

والصيغة الرياضية لهذه الطريقة تكون كما يلي:

أفرض أن لدينا C_i, C_j & C_k عبارة عن ثلاث مجموعات فالمسافة D بين C_i و C_j يمكن الحصول عليها من صيغة لانس – ويليامز Lance – Williams كالتالي:⁹

$$\begin{aligned}
 & D(C_k, C_i \cup C_j) \\
 &= \frac{1}{2} D(C_k, C_i) + \frac{1}{2} D(C_k, C_j) + \frac{1}{2} |D(C_k, C_i) - D(C_k, C_j)| \\
 &= \max \{D(C_k, C_i), D(C_k, C_j)\}. \dots \quad (9-3)
 \end{aligned}$$


طريقة الربط المتوسط: 4-2-3 Average Linkage Method:

طريقة الربط المتوسط تنظر للمسافة بين مجموعتين على أنها متوسط المسافة بين جميع الأزواج التي ينتمي أحد عناصرها إلى إحدى المجموعتين بينما ينتمي العنصر الآخر إلى المجموعة الأخرى ، كما يلي:

الشكل (3-3) الرابط المتوسط¹⁰

⁹ - مارتن تي ويلز وآخرون- تجميع البيانات - مرجع سابق ص (121).

¹⁰ - د. ریتشارد جونسون ، دیرن وشن ، مرجع سابق ص (866).



المجموعة الثانية

المجموعة الأولى

المصدر : اعداد الدرس باستخدام برنامج MS-Word

في هذه الحالة اذا افترضنا (A,B,C) تنتهي للمجموعة الاولى و (D,E,F) تنتهي الى المجموعة الثانية حيث يتم حساب المسافات بين الوحدات في المجموعة الاولى مع المجموعة الثانية لإيجاد متوسط المسافة لاستخدامها في قياس الاختلاف بين المجموعتين

والصيغة الرياضية لهذه الطريقة تكون كما يلي:

أفرض أن لدينا $C_i, C_j \& C_k$ عبارة عن ثلاثة مجموعات فالمسافة D بين C_i و C_j يمكن الحصول عليها من صيغة لانس - ويليامز Lance - Williams كالتالي:¹¹

$$D(C_k, C_i \cup C_j) = \frac{|C_i|}{|C_i| + |C_j|} D(C_k, C_i) + \frac{|C_j|}{|C_i| + |C_j|} D(C_k, C_j) \dots \quad (10-3)$$

أفرض أن C, C' عبارة عن مجموعتين غير خاليتين عليه يمكن إيجاد المسافة بطريقةربط المتوسط الآتي:

$$D(C, C') = \frac{1}{|C||C'|} \sum_{x \in C, y \in C'} d(x, y) \dots \quad (.11-3)$$

أفرض أن C_1, C_2, C_3 عبارة عن ثلاثة مجموعات غير خالية عليه أفرض أن :

$$D(C_i, C_j) = \frac{1}{n_i n_j} \sum (C_i, C_j), 1 \leq i \leq j \leq 3 \dots \quad (12-3)$$

حيث:

¹¹ مارتن تي ويلز وآخرون- تجميع البيانات - مرجع سابق ص (123)

$$C_i, C_j . \sum(C_i, C_j) = n_i = |C| \& n_j = |C_j|$$

هذا يعني أن:

$$\sum(C_i, C_j) = \sum_{x \in C_i, y \in C_j} d(x, y)$$

ومن المعادلات (11-3) و (12-3) نستنتج:

$$\begin{aligned} D(C_k, C_i \cup C_g) \\ = \frac{n_2}{n_2 + n_3} D(C_1, C_2) + \frac{n_3}{n_2 + n_3} D(C_1, C_3) \\ = \frac{n_2}{n_2 + n_3} \cdot \frac{1}{n_1 n_2} \sum(C_1, C_2) + \frac{n_3}{n_2 + n_3} \cdot \frac{1}{n_1 n_2} \sum(C_1, C_3) \\ = \frac{1}{n_1(n_2 + n_3)} \sum(C_1, C_2 \cup C_3) \end{aligned}$$

بعد ذلك:

$$\sum(C_1, C_2) + \sum(C_1, C_3) = \sum(C_1, C_2 \cup C_3)$$

وهذا يتحقق أيضاً للمعادلة (11-3)

هناك عدة طرق للتجميع النظرية الإحصائية ونتناول فيما يلي بشكل موجز إثنين من أهم هذه الطرق وهي طريقة التجميع المتدرجة وطريقة K متوسط واللتين سيتم تطبيقهما في التجميع وسنفترض أن المطلوب هو تجميع وحدات وليس متغيرات وهي الحالة التي تهمنا

3-2-5 طرق التجميع المتدرجة: Clustering Methods

هناك نوعان من طرق التجميع المتدرجة :

1- طريقة الفصل المتدرجة *Divisive hierarchical methods*، حيث نبدأ بمجموعة تتضمن جميع العناصر ثم تقسم هذه المجموعات إلى مجموعتين فرعيتين بحيث تكون العناصر الموجودة في مجموعة منها "بعيدة" عن العناصر الموجودة في المجموعة الأخرى ، يتم بعد ذلك تقسيم كل

من هاتين المجموعتين إلى مجموعات فرعية غير مماثلة ، نستمر في ذلك حتى يكون لدينا عدداً من المجموعات الفرعية مساوياً لعدد العناصر ، أي حتى يكون كل عنصر مجموعة بنفسه.¹²

2- طريقة التجميع المتدرجة Agglomerative Hierarchical Methods وهي إحدى طرق الإدماج "linkage methods" المتتالية التي تلائم تجميع المفردات وكما تلائم تجميع المتغيرات وهذا لا يتحقق بالنسبة لجميع طرق الإدماج المتدرجة الأخرى ، وفيما يلي خطوات تنفيذ الطرق التجميع المتدرجة لإدماج المجموعات عند وجود N من العناصر (المفردات أو المتغيرات) وتسمى هذه الخطوات بالطريقة العامة:¹³

1- نبدأ بعدد N من المجموعات ، كل مجموعة بها عنصر واحد ونوجد مصفوفة المسافة (أو مصفوفة قيم معامل التماثل المستخدم) $D = d_{ik}$ وهي مصفوفة متماثلة أبعادها $(N \times N)$

2- نبحث في مصفوفة المسافة عن أقرب زوج من المجموعات (الزوج الأكثر تماثلاً). نفترض أن d_{uv} تشير إلى المسافة بين الزوج الأكثر تماثلاً U, V .

3- ندمج المجموعة U مع المجموعة V ، ونستخدم الرمز $(V U)$ للإشارة إلى المجموعة الجديدة ، ونعدل من عناصر مصفوفة المسافة على النحو التالي:

(a) نحذف الصور والأعمدة المناظرة للمجموعتين U ، V .

(b) نصف صفاً عموداً جديدين يعطيان المسافة بين المجموعة الجديدة $(V U)$ والمجموعات الأخرى


4- نكرر الخطوتين (a) ، (b) عدد $N - 1$ من المرات (في النهاية تجمع جميع العناصر في مجموعة واحدة) تقوم بتسجيل هوية المجموعات التي أدمجت والمسافات (أو قيم معامل التماثل المستخدم) التي تم عندها الإدماج.

¹² www.norusis.com/pdf/spc-v13.pdf.

¹³ د. ريتشارد جونسون ، ديرن وشن ، مرجع سابق ص (867) .

ويمكن عرض نتائج هاتين الطريقتين بيانياً في فراغ ذي بعدين في شكل بياني يعرف باسم "الدندوج رام" .¹⁴

الشكل (4-3) طريقة التجميع المتدرج وطريقة الفصل المتدرج¹⁴



1. المصدر : فرح عبدالله محمد , (2010) ، "تصنيف الولايات السودانية ذات الخصائص الديمغرافية المتشابهة بإستخدام التحليل العنقودي للعام 2002 م" ، جامعة السودان للعلوم والتكنولوجيا .

نلاحظ في الشكل اعلاه في حالة التجميع المتدرج في الخطوة Step0 اعلى الشكل ان كل مفردة تعتبر عنقود لوحدها وعند اجراء عملية التجميع ننتقل الي الخطوة Step1 لنجد ان العنقودين a,b تم دمجها في عنقود واحد نسبة لوجود تقارب بينهما اما البقية (c,d,e) تظل في عناقيد لوحدها ، وفي الخطوة Step2 نلاحظ ان العنقودين (d,e) تم جمعهما معا في عنقود واحد نسبة لدرجة التقارب بينهما والبقية (a,b) في عنقود و (c) في عنقود لوحدها ، في الخطوة Step3 تم دمج العنقود (c) مع العنقود (d,e) ليصير لدينا عنقودين فقط هما (c,d,e) و (a,d) اما في الخطوة Step4 تم تجميع اخر عنقودين من الخطوة Step3 في عنقود واحد كبير يجمع جميع العناقيد في الخطوة Step0 في عنقود واحد وبذلك تكون طريقة التجميع المتدرج وصلت الى آخر خطوة.

.¹⁴ كي سينق زاهنق - وسائل التحليل العنقودي في البيانات البحثية رسالة دكتوراة جامعة ماكورى سدنى - أستراليا 2007م.

اما في خطوة الفصل المتدرج اسفل الشكل ففي الخطوة Step0 نجد ان هذه الطريقة تعتبر كل العناصر عبارة عن عقد واحد كبيرة وعند الانتقال للخطوة الاولى في الطريقة Step1 نجد انه تم فصل العنصرين (a,b) عن العقد الكبير لتصبح عقد لوحدها والباقيه تصبح (c,d,e) وفي عند الانتقال الى الخطوة Step2 نجد ان العنصر (c) انفصل عن العقد الكبير واصبح عدد العناقيد 3 وهي (a,b) و (c) و (d,e) وفي الخطوة Step3 نجد ان العقد (d,e) قد انفصل الى عقددين هما (d) و (e) فاصبح عدد العناقيد اربعة وهي (a,b) و (c) و (d) و (e) وفي الخطوة الختامية لطريقة الفصل المتدرج تكون كل العناصر قد اصبحت في عناقيد كل على حده.

ونلاحظ ان كلا الطريقتين تعاملان عكس بعضهما الاولى تجمع بالتدريج والاخرى تفصل بالتدريج

6-2-3 مصفوفة القرابة¹⁵ Proximity Matrix:

هي مصفوفة متماثلة مدخلاتها عبارة عن مربع المسافة الإقليدية لكل زوج من الحالات الجدول رقم (3-1) يمثل نموذج لمصفوفة القرابة ، ونلاحظ أن قيم القطر الرئيسي (0) مما يعني أنه لا توجد فروق بين الحالة نفسها وكذلك القيمة (2.6) تعني أن المسافة بين (E) و(D) هي عبارة عن أصغر قيمة في المصفوفة مما يعني أنها متماثلين بدرجة عالية ، وأيضاً نجد القيمة (12.8) تعني أن المسافة بين (F) و(G) هي أكبر المسافات الإقليدية مما يعني أنها على درجة عالية من عدم التماثل.

1-د. محفوظ جودة ، التحليل الإحصائي المتقدم باستخدام SPSS دار وائل للطباعة والنشر - عمان الأردن الطبعة الأولى 2008م ص(100)

جدول (1-3) مصفوفة الاقرابة

samples	A	B	C	D	E	F	G
A	0	7.5	10.4	6.4	4.7	6.6	8.8
B	7.5	0	12.4	9.3	5.6	9.2	8.8
C	10.4	12.4	0	5.4	3.7	9.1	10.6
D	6.4	9.3	5.4	0	2.6	5.4	10.7
E	4.7	5.4	3.7	2.6	0	4.7	5.4
F	6.6	9.2	9.8	5.7	4.8	0	12.8
G	8.8	8.8	10.6	10.7	5.4	12.8	0

المصدر : المرجع نفسه، ص[19]

7-2-3: شكل الألواح الجليدية : The Icicle Plot

هو عبارة عن شكل يبين الطريقة التي تتم بها دمج الحالات في كل خطوة من خطوات التحليل العنقودي ، ويسمى شكل الألواح الجليدية لأن لها نفس شكل الألواح الجليدية المتشكّلة من مساقط الماء.¹⁶ ولكي نتمكن من فهمه لابد أن نقرأه من أسفل إلى أعلى.

شكل (5-3) الألواح الجليدية¹⁷

		Case							
		5	8	6	7	3	2	4	1
عدد العناقيد	1	x x x x x x x x x x x x x x x x x x x							
	2	x x x x x x x x x x x x x x x x x x x						x x x	
	3	x x x x x x x x x x x x x x x x x x x						x x x	
	4	x x x x x x x x x x x x x x x x x x x						x x x	
	5	x x x x x x x x x x x x x x x x x x x					x	x x x	
	6	x x x x x x x x x x x x x x x x x x x					x	x x x	
	7	x x x x x x x x x x x x x x x x x x x					x	x x x	
	8	x x x x x x x x x x x x x x x x x x x					x	x x x	

المصدر: المرجع نفسه ، ص[20]

8-2-3: خطوات التجميع¹⁸ The Agglomeration Schedule:

شكل الألواح الجليدية لا يمكن من معرفة أصغر مسافة إقلية بين الحالتين أو الحالات التي تم دمجها في عقود لذلك علينا اللجوء لما يسمى بخطوات التجميع جدول (3-3) فنجد في هذه الخطوة عمود يسمى المعامل Coefficient به قيم المسافات الإقلية قيم (التماثل) التي أستخدمت لتكوين العناقيد . أما عمود Stage Cluster First appears (يبيّن لنا الخطوة التي يظهر فيها العقود لأول مرة .

جدول (3-2) خطوات التجميع

المرحلة	الانضمام للعنقىد		المعاملات	الظهور اول مرة		المرحلة التالية
	العنقود 1	العنقود 2		العنقود 1	العنقود 2	
1	4	5	2.566	0	0	4
2	1	11	2.694	0	0	5
3	3	10	3.903	0	0	4
4	3	4	4.023	3	1	6
5	1	8	4.279	2	0	11
6	3	15	4.336	4	0	13
7	2	9	5.205	0	0	14

المصدر : المرجع نفسه، ص[21]

9-2-3: الديندوغرام The Dendrogram

هو عبارة عن شكل بياني يوضح المسافات التي تم فيها تكوين العناقيد ويشير ذلك في الشكل رقم (3-3) ويقرأ من الشمال إلى اليمين الخطوط العمودية تشير إلى العناقيد المدمجة فموقع الخط يشير إلى المسافة التي تمت فيها عملية الدمج وتكون العناقيد ، فأول عمود رأسي يقابل أصغر مسافة إقليدية ولكي نفهم شكل الديندوغرام لابد لنا ان نعرف مايسما بالـ . n-tree :

أفرض ان $(x_1, x_2, \dots, x_n) = D$ وأن L مجموعة جزئية من D تحقق الشروط التالية:

$$J \in D . 1$$

$$\text{Empty set } \Phi \in J . 2$$

For all

.3

$$\left\{ x_i \right\}_{i=1,2,3,\dots,n} \in J$$


if $A, B \in B \cap J,$

.4

$$\text{then } A \in \{\Phi, A, B\}.$$

ا. لـ n-tree في الشكل (3-6) العقد الطرفية المرسومة بدائرة فقط من غير تظليل تبين البيانات بصورة مفردة ، أما العقد المرسومة بدوائر مظللة المجموعات أو العناقيد .

الشكل (6-3) الشجرة ن - 5-tree¹⁹



X_1 الى X_5 = الوحدات التي تتكون منها العناقيد

[22] المصدر : المرجع نفسه ، ص

من ذلك نستطيع أن نصف شكل الديندو جرام بأنه شجرة تعرف بالـ 5-tree). يحقق الشرط التالي:

لكل مجموعة جزئية من البيانات A و B بشرط

عندما $h(A) \& h(B)$ تعرف الارتفاعات لـ (A, B) على التوالي .

من الشكل أعلاه أفرض أن (h_{ij}) عبارة عن إرتفاع زوج البيانات (X_i, X_j) فالقيمة الأصغر h_{ij} تمثل أكبر معامل تمايز أو تشابه بين (X_i, X_j) وكذلك أكبر قيمة h_{ij} تمثل أصغر قيمة لمعامل التمايز أو تشابه بين (X_i, X_j) .

الارتفاع في الدينوجرام يحقق الشرط التالي:

ويمكن عرض شكل الدينار جرام رياضياً بالمعادلة التالية:

¹⁹ - مارتن تي ويزل وآخرون- تجميع البيانات - مرجع سابق ص (112)

$$C : [(0, \infty) \rightarrow E(D)]$$

التي تتحقق:

$$c(h) \subseteq c(h') \rightarrow if \leq h'$$


$c(h)$ is eventually in $D \times D$

$$c(h + \delta) = c(h) \text{ for some small } \delta > 0$$

عندما يكون لدينا المجموعة D و $E(D)$ عبارة

عن مجموعة من العلاقات المتكافئة في D ويمكن تمثيل ذلك بالشكل التالي:

شكل (7-3) ديندوجرام لخمسمجموعات²⁰



المصدر : المرجع نفسه ، ص [23]

X_1 الى X_5 = الوحدات التي تتكون منها العناقيد


المعادلة (c) تحوي المعلومات في شكل الديندوجرام ويمكن بيان ذلك من الشكل (8-3) كالتالي:

$$c(h) = \begin{cases} \{(i, i) : i = 1, 2, 3, 4, 5\} if 0 \leq h < 1, \\ \{(i, i) : i = 3, 4, 5\} \cup \{(i, j) : i, j = 1, 2\} if 1 \leq h < 2 \\ \{(3, 3)\} \cup \{(i, j) : i, j = 1, 2\} \cup \{(i, j) : i, j = 4, 5\} if 2 \leq h < 3(15-3) \\ \{(i, j) : i, j = 4, 5\} \cup \{(i, j) : i, j = 1, 2, 3\} if 3 \leq h < 4 \\ \{(i, j) : i, j = 1, 2, 3, 4, 5\} if 4 \leq h \end{cases}$$

شكل (8-3) الديندوجرام²¹

²⁰ - مارتن تي ويلز آخرون- تجميع البيانات - مرجع سابق ص (112)

www.uga.edu/strata/software/pdf/cluster²¹



المصدر : المرجع نفسه، ص [24]

10-2-3: طريقة K من المتوسطات

هي إحدى طرق التجميع غير المتردجة Nonhierarchical Clustering Methods

لتجميع المفردات وليس المتغيرات في K من المتوسطات، اقترح MacQueen عام 1976م اسم K من المتوسطات (K-means) لوصف طريقته وتعتبر من أبسط طرق العنقدة وأكثرها شيوعاً وذات كفاءة عالية ، وتستخدم ما يسمى النقاط المركزية (Centroids) التي تضع كل مفردة في المجموعة التي يكون وسطها الحسابي أقرب لها ، وتن تكون هذه الطريقة في أبسط صورها من ثلاثة خطوات²² هي:

- 1- تقسيم المفردات إلى K من المجموعات الأولية.
- 2- وضع كل مفردة من المفردات الموجودة في المجموعة التي يكون وسطها الحسابي أقرب ما يكون لها (عادة ما تستخدم المسافة الإقليدية لحساب المسافة سواء تم ذلك باستخدام المشاهدات الفعلية

أو المشاهدات المعيارية) نعيد حساب الوسط الحسابي للمجموعة التي أضيفت إليها المفردة الجديدة وللمجموعة التي فقدت منها المفردة.

3- نكرر الخطوة الثانية إلى أن تتوقف عملية توزيع المفردات على المجموعات ، ويدلاً من أن نبدأ في الخطوة الأولى بتجزئة جميع المفردات إلى K من المتوسطات من المجموعات الأولية ، فإنـه يمكننا البدء بتحديد k ، (نقاط الأساس) ثم نقوم بتنفيذ الخطوة الثانية.

ويعتمد التوزيع النهائي للمفردات على المجموعات إلى حد ما ، على التقسيم الأولي المستخدم أو على الاختيار الأولي لنقاط الأساس .

توجد بعض الحجج القوية التي تؤيد عدم تحديد عدد المجموعات K مسبقاً²³ ومن بينها:

1- إذا وقعت نقطتين أو أكثر من نقاط الأساس ، دون تعمد ، في مجموعة واحدة، فإنه من الصعب التمييز بين المجموعات الناجمة عن ذلك.

2- قد يؤدي وجود مشاهدة شاذة في الحصول على مجموعة واحدة على الأقل متاثرة بالمفردات.

3- وحتى إذا تكون المجتمع من K من المجموعات ، فإن طريقة المعاينة المستخدمة يمكن أن تؤدي إلى عدم احتواء العينة على بيانات من المجموعة الأصغر. في هذه الحالة، يؤدي توزيع البيانات على K من المجموعات إلى وجود مجموعات ليس لها معنى.

المثال التالي يوضح طريقة التجميع بواسطة الـ (K) متوسط:

أفرض أننا نستطيع قياس المتغيرين X_1 ، X_2 لكل مفردة من المفردات كما في الجدول التالي:

جدول (3-3) قيم المتغيرين X_1 ، X_2

²³د. ريتشارد جونسون ، ديرن وشن، مرجع سابق ص (893) .

المفرد	X1	X2
A	5	3
B	-1	1
C	1	-2
D	-3	-2

المصدر : (فرح عبدالله ، [2010])

الهدف هو تقسيم هذه المفردات لمجموعتين أي $K=2$ بحيث يكون قرب المفردات الموجودة في أي مجموعة من بعضها البعض أكبر من قربها من مفردات المجموعات الأخرى.

- نقوم بتقسيم المفردات عشوائياً لمجموعتين (AB) والمجموعة (CD).

- نقوم بحساب إحداثيات المركز (\bar{X}_1, \bar{X}_2) لكل مجموعة كالتالي:

جدول (4-3) احداثيات مركز X_1, X_2

المجموعة	\bar{X}_1	\bar{X}_2
AB	2	2
CD	-1	-2

المصدر : المرجع نفسه ، ص [26]

نقوم بحساب المسافة الإقليدية بين كل مفردة وبين إحداثيات نقطتي المركز بين كل مفردة وبين إحداثيات نقطتي المركز ونعيد توزيع كل مفردة على المجموعة الأقرب لها ، ولذا انتقلت مفردة ما من مجموعة إلى أخرى يجب تعديل نقاط المركز المناظرة قبلمواصلة العمل كالتالي:

$$d^2(A.(AB)) = (5-2)^2 + (3-2)^2 = 10$$

$$d^2(A,(CD)) = (5+1)^2 + (3+2)^2 = 61$$

حيث أن المفردة A أقرب إلى المجموعة (AB) منها للمجموعة (CD) فتبقي في مجموعتها.

وبمواصلة حساب المسافات المرتبطة :

$$d^2(B.(AB)) = (-1-2)^2 + (1-2)^2 = 10$$

$$d^2(B,(CD)) = (-1+1)^2 + (1+2)^2 = 9$$

وبالتالي نقوم بوضع المفردة B في المجموعة (CD) لنجعل على المجموعة (BCD) كما نحصل على نقاط المركز الجديدة التالية:

جدول (3-5) احداثيات المركز الجديدة X_1, X_2

المجموعة	\bar{X}_1	\bar{X}_2
A	5	3
CDB	-1	-1

المصدر : المرجع نفسه ، ص [27]

ومرة أخرى نقوم بفحص كل مفردة لمعرفة إمكانية إعادة توزيع المفردات وبحساب المسافات الإقليدية نحصل على ما يلي:

جدول (3-6) توزيع المجموعات النهائي²⁴

المجموعة	A	B	C	D
A	0	40	41	89
CDB	52	4	5	5

المصدر : المرجع نفسه ، ص [27]

من ذلك يكون كل مفردة قد تم وضعها في المجموعة التي يكون مركزها أقرب ما يكون لها وبالتالي تتوقف العملية أي أننا نحصل في النهاية على المجموعتين A و (BCD).

²⁴ ريتشارد جونسون ، ديرن وشن ، مرجع سابق ص (887)