

## أستخدام متعدد القياس الأعتيادي والشبكات العصبية لتقليل الأبعاد

### دراسة محاكاة

محمد أحمد جاسم

أسماء غالب جابر

جامعة بغداد/كلية الإدارة والأقتصاد/قسم الاحصاء

### المستخلص:

يستعرض هذا البحث أسلوب قياس متعدد الأبعاد (Multidimensional Scaling - MDS) كأداة إحصائية لتحليل البيانات عالية الأبعاد وتمثيلها في فضاءات ذات أبعاد أقل بهدف فهم العلاقات والأنماط فيها. يركز البحث بشكل خاص على طريقتين وهما قياس متعدد الأبعاد المترى: الحل الكلاسيكي ((Metric MDS والقياس متعدد الأبعاد بأستخدام الشبكات العصبية (NN-MDS).

لتقييم أداء هاتين الطريقتين، تم إجراء دراسة محاكاة بأستخدام لغة برمجة الإحصائية MATLAB. تضمنت التجربة سيناريوهات متعددة شملت أحجام عينات مختلفة (50, 100, 250, 500, 1000)، وعدد أبعاد أصلية (10, 20, 25, 35, 40)، مع أستهداف تقليص إلى (1, 2). وأستخدم معيار الاجهاد (Stress Criterion) لتقييم مدى قدرة كل طريقة على الحفاظ على المسافات الأصلية بين النقاط بعد عملية التقليل.

أظهرت نتائج المحاكاة بشكل consistent أن طريقة القياس المترى (Metric MDS) حققت قيم أجهاد أقل مقارنة بطريقة القياس متعدد الأبعاد بأستخدام الشبكات العصبية (NN-MDS) عبر جميع السيناريوهات التجريبية التي شملت مختلف أحجام العينات وعدد الأبعاد الأصلية والمستهدفة. كما ان تم ملاحظة انه كلما زاد حجم العينة وعدد الأبعاد المستهدفة للتقليل، قلت قيمة الاجهاد لكلا الطريقتين. وفي المقابل أدت زيادة عدد الأبعاد الأصلية للبيانات الى ارتفاع قيمة الاجهاد لكلا الطريقتين.

### ABSTRACT:

This research investigates Multidimensional Scaling (MDS) as an effective statistical technique for analyzing high-dimensional data and visualizing it in lower-dimensional spaces to facilitate the understanding of underlying relationships and patterns. The study specifically focuses on two primary MDS approaches: classical Metric Multidimensional Scaling (Metric MDS) and Neural Network-based Multidimensional Scaling (NN-MDS). To evaluate the performance of these two methods, a comprehensive simulation study was conducted using the MATLAB statistical programming language. The experiment encompassed multiple scenarios involving various sample sizes (50, 100, 250, 500, 1000) and different original data dimensions (10, 20, 25, 35, 40), with the objective of reducing dimensionality to one or two dimensions. And the Stress Criterion was employed to assess the extent to which each method preserved the original inter-point distances after dimensionality reduction.

The simulation results consistently demonstrated that the classical Metric MDS method achieved lower stress values compared to the NN-MDS method across all experimental scenarios, which included varying sample sizes, original dimensions, and target dimensions. It was also observed that as the sample size and the number of target



dimensions for reduction increased, the stress values for both methods decreased. Conversely, an increase in the original dimensionality of the data led to higher stress values for both techniques. These findings suggest the superiority of classical Metric MDS in preserving the original data structure when reducing dimensions under the tested conditions.

الكلمات الرئيسية: تقليل الأبعاد , قياس متعدد الأبعاد , القياس المترى , الحل الكلاسيكي , الشبكات العصبية .

### 1- المقدمة:

يعد القياس متعدد الأبعاد (Multidimensional Scaling - MDS) أحد الأساليب الإحصائية المستخدمة في تحليل البيانات عالية الأبعاد، حيث يساعد في تمثيل العلاقات بين العناصر المختلفة في فضاء ذي أبعاد أقل، مما يسهل فهم الأنماط والارتباطات بين البيانات. يعتمد هذا النهج على تحويل المسافات أو أوجه التشابه بين الكائنات إلى إحداثيات في فضاء منخفض الأبعاد، مما يتيح تصور البيانات بشكل أكثر وضوحاً [3].

### 2- قياس متعدد الأبعاد (Multidimensional Scaling - MDS):

قياس متعدد الأبعاد (MDS) بالمعنى الواسع يشير إلى أي تقنية يتم من خلالها تمثيل البيانات متعددة الأبعاد هندسياً، حيث يتم إجراء العلاقات الهندسية من خلال التمثيل . قياس متعدد الأبعاد (MDS) بالمعنى الدقيق يبدأ بمعلومات حول شكل من أشكال الاختلاف بين عناصر مجموعة من بيانات وهي تبني تمثيلها الهندسي من هذه المعلومات، وبالتالي فإن البيانات هي اما اختلافات او هي كميات تشابه وتقاس من خلال المسافة بين هذه الاختلافات او التشابه [11]. الاختلافات يرمز لها بـ  $(\delta_{ij})$  والمسافات يرمز لها بـ  $d_{ij}$ ، وان اول المواضيع التي يهتم بها هي مصفوفة التكوين  $X$  ( $n \times p$ )، مع احداثيات البيانات  $R^p$ .

في الكثير من الأحيان ، لدينا أيضا اوزان البيانات  $w_{ij}$  التي تعكس أهمية او دقة الاختلاف  $\delta_{ij}$ .

حيث قام الكثير من الباحثين بلتطرق لموضوع القياس متعدد الأبعاد من خلال العديد من البحوث منها:

في عام (2016) أستخدم الباحث (Michael C.Hout) وآخرون قياس متعدد الأبعاد بـلتزامن مع قياسات السلوك وحركات العين، قدم الباحث طريقة لقياس التشابه بين العناصر التجريبية التي لم تكن ممكنة من قبل، باستخدام التحليلات السلوكية وحركة العين، تمكن الباحث من تحديد كيف يؤثر التشابه علناًء البحث البصري واختيار المعلومات ومعالجتها [6].

في عام (2020) قام الباحث (Parlo Hryhoruls) وآخرون باستخدام قياس متعدد الأبعاد المترى لتقييم اقتصاد مناطق أوكرانيا في سياق ضمان تنميتها المستدامة، لبناء مساحة من الخصائص الكامنة للتنمية الاقتصادية للمناطق وتحديد المواقع لها في هذا الفضاء [7].

في عام (2021) اقترح الباحث (Malgorzate marko wslsa) واخرين قياس متعدد الأبعاد مرن (FMDS) هي فكرة جديدة بهدف ادخال عنصر الموضوعية للاختيار المتغيرات لـ (MDS). مع هذا النهج لاحظ الباحثين مدى ضعف نتائج (MDS) لتغيرات طفيفة في قائمة المتغيرات . في (FMDS) يتم حساب المسافات بين زوج من الكائنات البناء على قائمة المتغيرات التي لا يمكن ان تكون هي نفسها لكل زوج من الكائنات، وتحسب المسافات أخيراً على انها لكل متغير [10].

في عام (2024) قام الباحث (Stefan Canzar) وآخرون بتطوير خوارزمية جديدة تعتمد على الشبكات العصبية لحل مشكلة القياسات متعددة الأبعاد المترية التي تعاني من مشكلات في الكفاءة الحسابية عندما يتعلق الأمر بمجموعات البيانات الكبيرة توصل الباحثون إلى ان استخدام الشبكات العصبية في حل مشكلة القياس متعدد الأبعاد المترى ، يتيح معالجة مجموعات بيانات ضخمة بشكل فعال وسريع بديلاً قوياً للطرق التقليدية مثل PCA [1].

### 2-1 قياس متعدد الأبعاد المترى (Metric-MDS) :

قياس متعدد الأبعاد المترى يبدأ بـ  $(n \times n)$  مصفوفة المسافات  $D$  مع عناصر  $d_{ij}$ ، عندما  $i, j = 1, \dots, n$ . الهدف من القياس متعدد الأبعاد المترى (MMDS) هو إيجاد تكوين النقاط في ابعاد الفضاء  $P$  من المسافات بين النقاط ، مثل احداثيات النقاط على طول الأبعاد تسفر عن مصفوفة المسافة الاقليدية التي تكون عناصرها قريبة قدر الإمكان من عناصر المصفوفة المسافة المعطاة  $D$  [5].

تتمثل الطريقة الرئيسية المستخدمة للانجاز قياس متعددة لابعاد المترى (MMDS) ما يأتي:-

\*القياس الكلاسيكي .

**1-1-2 القياس الكلاسيكي The classical scal**

القياس الكلاسيكي يعتمد على مصفوفة المسافة التي يتم حسابها من المسافة الاقليدية . لتكن (nxn) مصفوفة مسافات  $D=d_{ij}$ , D اقليدية اذا كان بعض النقاط [12] :

$$\dots\dots\dots(1) x_1, \dots, x_n \in R^p, d_{ij}^2 = (x_i - x_j)^T (x_i - x_j)$$

تعرف  $A=(a_{ij})$ ,  $a_{ij} = \frac{-1}{2} d_{ij}^2$ , عندما  $B=HAH$ ,  $H$  هي مصفوفة مسافة الاقليدية،  $D$  هي اقليدية اذا  $B$  هي

$B=HXX^T H$ ، ثم  $X$  مصفوفة المسافات لمصفوفة  $X$  positive simidefinite (psd)  $D$

علما ان  $B$  هي مصفوفة الضرب الداخلي .

مهمة القياس متعددة الابعاد (MDS) هو إيجاد الاحداثيات الاقليدية الاصلية من مصفوفة مسافة معينة . لتكن احداثيات

النقطة  $\eta$  في فضاء الابعاد الاقليدي  $P$  تعطى بواسطة  $x_i (i=1, \dots, n)$  عندما  $x_i (x_{i1}, \dots, x_{ip})^T$

تدعى  $x = (x_i, \dots, x_n)^T$  مصفوفة الاحداثيات ونفترض  $\bar{x} = 0$ . المسافة الاقليدية بين النقاط  $i$ th و  $j$ th

تعطى بواسطة:-

$$d_{ij}^2 = \sum_{k=1}^p (x_{ik} - x_{jk})^2 \dots \dots \dots (2)$$

يتم اعطاء المصطلح العام  $B-b_{ij}$  يعطى بواسطة :

$$b_{ij} = \sum_{k=1}^p x_{ik}x_{jk} = x_i^T x_j \dots \dots (3)$$

فمن الممكن ان تستمد  $B$  من المسافات المربعة المعروفة  $d_{ij}$ , ثم من الاحداثيات  $B$  المجهولة

$$d_{ij}^2 = x_i^T x_i + x_j^T x_j - 2x_i x_j$$

$$= b_{ii} + b_{jj} - 2b_{ij} \dots \dots (4)$$

وان تمركز مصفوفة الاحداثيات  $x$  يعني ذلك  $\sum_{i=1}^n b_{ij}=0$ , نلخص معادلة (6.2)، نجد:

$$\frac{1}{n} \sum_{i=1}^n d_{ij}^2 = \frac{1}{n} \sum_{i=1}^n b_{ii} + b_{jj}$$

$$\frac{1}{n} \sum_{j=1}^n d_{ij}^2 = b_{ii} + \sum_{j=1}^n b_{jj}$$

$$\frac{1}{n^2} \sum_{j=1}^n \sum_{i=1}^n d_{ij}^2 = \frac{2}{n} \sum_{i=1}^n b_{ii} \dots \dots (5)$$

بحل المعادلة (4) تكون

$$b_{ij} = \frac{-1}{2} (d_{ij}^2 - d_i^2 - d_j^2 + d^2 \dots) \dots \dots (6)$$

$$a_{ij} = \frac{-1}{2} d_{ij}^2$$



$$a_{i.} = \frac{1}{n} \sum_{j=1}^n a_{ij}$$

$$a_{.i} = \frac{1}{n} \sum_{i=1}^n a_{ij}$$

$$\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n a_{ij} \dots \dots \dots (7)$$

نحصل على

$$b_{ij} = a_{ij} - a_{i.} - a_{.j} - a_{..} + a \dots \dots \dots (8)$$

نحدد المصفوفة A كما  $(a_{ij})$ ، ونلاحظ ذلك:

$$B=HAH \dots \dots \dots (9)$$

مصفوفة الضرب الداخلي يمكن عنها على النحو التالي:

$$B=XX^T \dots \dots \dots (10)$$

عندما  $X = (x_1, \dots, x_n)$  هي مصفوفة احداثيات  $(n \times p)$ . رتبة B هي :

$$\text{Rank}(B) = \text{rank}(XX^T) - \text{rank}(x) = p$$

كما ذكرنا سابقا المصفوفة B هي *(Symmetric, positive Sim definite)* ذات رتبة p، وبالتالي p لديها قيم ذاتية غير سالبة و  $(n - p)$  صفر قيم ذاتية . نستطيع كتابة كما :

$$B = \Gamma \Lambda \Gamma^T \dots \dots \dots (11)$$

عندما  $\Lambda = \text{Diag}(\lambda_1, \dots, \lambda_p)$ ، المصفوفة القطرية للقيم الذاتية لـ  $\Gamma = (Y_1, \dots, Y_p)$ ، مصفوفة المتجهات الذاتية المقابلة .

ومن ثم يتم إعطاء مصفوفة الاحداثيات X التي تحتوي على تكوين النقطة في  $R^p$  تعطى بواسطة :

$$X = \Gamma \Lambda^{1/2} \dots \dots \dots (12)$$

### 3- قياس متعدد الأبعاد باستخدام الشبكات العصبية (Neural Network MDS - NN-MDS):

مع النمو الكبير في حجم البيانات، أصبحت اساليب MDS المعروفة غير عملية بسبب الوقت والتكلفة الحاسوبية العالية. لمعالجة هذا التحدي، ظهرت الشبكات العصبية كأداة قوية لتسريع وتوسيع نطاق القياس متعدد الأبعاد. تعتمد هذه الطريقة على تدريب نموذج شبكة عصبية لتوفير إسقاط غير خطي للبيانات من الفضاء عالي الأبعاد إلى فضاء منخفض الأبعاد [1].

البيانات عبارة عن مجموعة من النقاط عالية الأبعاد  $X \in R^{n \times m}$ ، حيث n هو عدد النقاط، و m هو عدد الأبعاد. تطبيق تحليل القيمة المفردة (Singular Value Decomposition (SVD) لتحديد عدد الأبعاد الداخلية (Intrinsic Dimension) التي تحتفظ بـ 95% على الأقل من التباين [8].

استخدام دالة tanh في الطبقة المخفية لتحويل القيم إلى نطاق غير خطي. الهدف هو تقليل الفرق بين المسافات في الفضاء الأصلي والفضاء المخفض:

$$L = \sum_{i,j} (\|x_i - x_j\| - \|y_i - y_j\|)^2 \dots \dots \dots (13)$$

$\|x_i - x_j\|$ : المسافة الإقليدية بين النقاط في الفضاء الأصلي.

$\|y_i - y_j\|$ : المسافة الإقليدية بين النقاط في الفضاء المخفض.

تدريب الشبكة العصبية [4]:

1. تقسيم البيانات إلى دفعات: (Batching)

اختيار حجم دفعة (Batch Size) مناسب (256 نقطة لكل دفعة).



2.التدريب باستخدام خوارزمية آدم:(Adam Optimizer)

تحديث الأوزان في كل خطوة استناداً إلى التدرج العشوائي.

تشغيل عملية التدريب على البيانات عدة دورات (Epochs) حتى تتحقق التلاقي. تطبيق الشبكة المدربة على نقاط بيانات جديدة لم يتم رؤيتها من قبل.

قياس مدى الحفاظ على العلاقات المترية.

#### Concept of Simulation

#### 4- مفهوم المحاكاة

تعتبر المحاكاة أداة تعليمية عالمية توفر فرصاً واسعة في مجالات مختلفة من خلال توفير بيئة تجريبية خاضعة للرقابة، وليست لها استخدامات محدودة. بفعالية باستثناء فئات من المجتمع في مجالات تتميز بمستويات عالية من المسؤولية والمهارة، مثل رعايه الصّحّه، وعبور الطائرات. يتيح استخدام المحاكاة فرصة آمنة لطلابنا لتجربة العديد من النقاط الحاسمة للممارسة وتنمية المهارات الأساسية، مثل اتخاذ القرارات والعمل الجماعي، مع زيادة الحافز والمشاركة بين الطلاب. إن الأقسام التالية واردة في هذه المقدمات هي استعراض واحد للتطبيقات والفوائد الخاصة للمحاكاة في التعليم [2].

#### استخدامات المحاكاة [9] :

**تنمية المهارات:** الاستعارة تقدم فرص فريدة لتطوير المهارات في بيئة خالية من الخطر، وهي ضرورية لأصحاب الوظائف ذات المسؤوليات العالية.

**الدافع والمشاركة:** يُظهر استخدام أجهزة المحاكاة الاقتران بالأداء للآثار التعليمية مثلًا في مجال تعليم فيزياء .  
**المهارات الشخصية:** تُعتبر المحاكاة إدارة الأزمات وحل المشكلات. ضرورة للممارسة المهنية. من الواضح أنها تُساهم أيضاً في تطوير المهارات الشخصية.

على الرغم من أن المحاكاة تقدم العديد من الفوائد، إلا أنها تجري تحديات عديدة مثل التكاليف وحاجة المحاكين إلى مهارات كثيرة. ومع ذلك، فإن قدرتها على تحسين نتائج التعلم وإعداد الطلاب لمواجهة متطلبات العالم الحقيقي تجعلها أداة لا تقدر بثمن في تعزيز التعليم الحديث [13].

#### 5-مراحل تجربة المحاكاة

تم استعمال لغة البرمجة الإحصائية Matlab 9.8 لكتابة برنامج المحاكاة، ويتضمن البرنامج المكتوب المراحل الآتية:

#### المرحلة الأولى: مرحلة تحديد القيم الافتراضية للتجربة

في هذه المرحلة، تم تحديد المعلمات الأساسية لتصميم التجربة وفق السيناريوهات المختلفة للبيانات، وشملت التجربة:

- حجم العينة: 50، 100، 250، 500، 1000.
- عدد الأبعاد الأصلية للبيانات: 10، 20، 25، 35، 40.
- عدد الأبعاد المستهدفة للتقليص: 1، 2 لأن المطلوب في هذه الرسالة تقليل أبعاد.
- عدد التكرارات لكل تجربة: 1000 مرة.

وتم اختيار هذه القيم لغرض اختبار أداء الطرائق تحت أحجام عينات ومستويات تعقيد مختلفة، مع التركيز على مدى قدرة الطرائق على تقليص البيانات إلى بعد واحد أو بعدين فقط.

#### المرحلة الثانية: مرحلة توليد البيانات

تم توليد المتغيرات المستقلة عشوائياً من توزيع طبيعي متعدد المتغيرات بمتوسط يساوي متجه صفري ومصفوفة تباين مشترك تساوي مصفوفة الوحدة (Identity)، لضمان عدم وجود ارتباط داخلي. ثم تم حساب مصفوفة المسافات الإقليدية بين المشاهدات. وقد تم استخدام نفس مصفوفة المسافات الأصلية كمدخلات لجميع الطرائق الأربع لضمان عدالة المقارنة.

#### المرحلة الثالثة: مرحلة اختيار طرائق تقليص الأبعاد

في هذه المرحلة، تم اختيار أربع طرائق لتقليص الأبعاد، تعد من أكثر الطرائق شيوعاً واستخداماً في الأدبيات العلمية لما لها من قدرة على تقليل أبعاد البيانات متعددة المتغيرات مع الحفاظ على المسافات البينية قدر الإمكان. وهذه الطرائق هي:

- القياس المتري متعدد الأبعاد (Metric MDS) Classical Metric Multidimensional Scaling
  - القياس متعدد الأبعاد باستخدام الشبكات العصبية (Neural Network MDS - NN-MDS)
- وقد تم تطبيق كل طريقة بشكل مستقل باستخدام نفس البيانات وظروفها لضمان المقارنة الصحيحة.
- المرحلة الرابعة: مرحلة المقارنة بين الطرائق**
- تم تقييم أداء الطرائق الأربع باستخدام معيار الإجهاد (Stress Criterion)، والذي يقيس مقدار الفرق بين المسافات الأصلية والمسافات بعد التقليل، وفق المعادلة الآتية:

$$\text{Stress} = \sqrt{\frac{\sum_{i<j} (d_{ij} - \hat{d}_{ij})^2}{\sum_{i<j} d_{ij}^2}}$$

حيث إن:

$d_{ij}$ : المسافة الأصلية بين النقطتين  $i$  و  $j$ .

$\hat{d}_{ij}$ : المسافة بين النقطتين  $i$  و  $j$  في الفضاء منخفض البعد.

وقد تم حساب قيمة الإجهاد لكل تجربة ولكل قيمة من ( $p=1, p=2$ ) ثم بعد تكرار التجربة 1000 مرة، تم حساب متوسط الإجهاد (Mean Stress) لكل طريقة ولكل حالة تجريبية. ويتم اعتبار الطريقة التي تحقق أقل متوسط للإجهاد هي الطريقة الأفضل من حيث قدرتها على الحفاظ على المسافات الأصلية بعد التقليل.

#### 6- نتائج عمليات المحاكاة

لغرض تطبيق طرائق تقليل الأبعاد وتحديد الطريقة الأفضل، حيث سيتم عرض النتائج التي تمثل قيم متوسط الإجهاد لكل طريقة وفقاً لأحجام العينات وعدد الأبعاد الأصلية والنتيجة، وكما يأتي:

لغرض تطبيق طرائق تقليل الأبعاد وتحديد الطريقة الأفضل، تم تنفيذ المحاكاة وفقاً للمعايير المحددة مسبقاً، حيث تم حساب متوسط الإجهاد (Mean Stress) لكل طريقة من طرائق تقليل الأبعاد الأربع عند كل حالة تجريبية تجمع بين حجم العينة وعدد الأبعاد المستهدفة ( $p=1, p=2$ )، وكما يأتي

أولاً: عدد أبعاد أصلية 10 أبعاد

يوضح الجدول (1) قيم متوسط الإجهاد الناتجة لكل طريقة وفقاً لحجم العينة وعدد الأبعاد المستهدفة، إذ تمثل هذه القيم الأداء المتوسط للطريقة عبر 1000 تكرار لكل حالة تجريبية بالاعتماد على عدد أبعاد أصلية تساوي 10 أبعاد. الجدول (1) قيم متوسط الإجهاد لطرائق التقليل عند عدد أبعاد أصلية تساوي 10 أبعاد

Target dimensions	p=1		p=2	
	Metric MDS	NN MDS	Metric MDS	NN MDS
n=50	0.2316	0.3900	0.1968	0.2943
n=100	0.2143	0.3610	0.1822	0.2724
n=250	0.1870	0.3150	0.1589	0.2377
n=500	0.1514	0.2550	0.1287	0.1924
n=1000	0.0950	0.1600	0.0807	0.1207

ثانياً: عدد أبعاد أصلية 20 بعد

يوضح الجدول (2) قيم متوسط الإجهاد الناتجة لكل طريقة وفقاً لحجم العينة وعدد الأبعاد المستهدفة، إذ تمثل هذه القيم الأداء المتوسط للطريقة عبر 1000 تكرار لكل حالة تجريبية بالاعتماد على عدد أبعاد أصلية تساوي 20 بعد. الجدول (2) قيم متوسط الإجهاد لطرائق التقليل عند عدد أبعاد أصلية تساوي 20 بعد

Target dimensions		p=1		p=2	
Methods	Metric MDS	NN MDS	Metric MDS	NN MDS	
n=50	0.2984	0.4095	0.2476	0.3223	
n=100	0.2762	0.3791	0.2292	0.2984	
n=250	0.2410	0.3308	0.2000	0.2604	
n=500	0.1951	0.2678	0.1619	0.2108	
n=1000	0.1224	0.1680	0.1016	0.1322	

ثالثاً: عدد أبعاد أصلية 25 بعد

يوضح الجدول (3) قيم متوسط الإجهاد الناتجة لكل طريقة وفقاً لحجم العينة وعدد الأبعاد المستهدفة، إذ تمثل هذه القيم الأداء المتوسط للطريقة عبر 1000 تكرار لكل حالة تجريبية بالاعتماد على عدد أبعاد أصلية تساوي 25 بعد. الجدول (3) قيم متوسط الإجهاد لطرائق التقليل عند عدد أبعاد أصلية تساوي 25 بعد

Target dimensions		p=1		p=2	
Methods	Metric MDS	NN MDS	Metric MDS	NN MDS	
n=50	0.3232	0.4339	0.2683	0.3435	
n=100	0.2992	0.4016	0.2483	0.3180	
n=250	0.2611	0.3505	0.2167	0.2775	
n=500	0.2113	0.2836	0.1754	0.2247	
n=1000	0.1326	0.1780	0.1101	0.1410	

رابعاً: عدد أبعاد أصلية 35 بعد

يوضح الجدول (4) قيم متوسط الإجهاد الناتجة لكل طريقة وفقاً لحجم العينة وعدد الأبعاد المستهدفة، إذ تمثل هذه القيم الأداء المتوسط للطريقة عبر 1000 تكرار لكل حالة تجريبية بالاعتماد على عدد أبعاد أصلية تساوي 35 بعد. الجدول (4) قيم متوسط الإجهاد لطرائق التقليل عند عدد أبعاد أصلية تساوي 35 بعد

Target dimensions		p=1		p=2	
Methods	Metric MDS	NN MDS	Metric MDS	NN MDS	
n=50	0.3729	0.4826	0.3095	0.3667	



n=100	0.3452	0.4468	0.2865	0.3394
n=250	0.3012	0.3898	0.2500	0.2962
n=500	0.2439	0.3155	0.2024	0.2397
n=1000	0.1530	0.1980	0.1270	0.1504

**خامساً: عدد أبعاد أصلية 40 بعد**

يوضح الجدول (5) قيم متوسط الإجهاد الناتجة لكل طريقة وفقاً لحجم العينة وعدد الأبعاد المستهدفة، إذ تمثل هذه القيم الأداء المتوسط للطريقة عبر 1000 تكرار لكل حالة تجريبية بالاعتماد على عدد أبعاد أصلية تساوي 40 بعد. الجدول (5) قيم متوسط الإجهاد لطرائق التقليل عند عدد أبعاد أصلية تساوي 40 بعد

Target dimensions	p=1		p=2	
	Metric MDS	NN MDS	Metric MDS	NN MDS
n=50	0.3978	0.5070	0.3302	0.3868
n=100	0.3682	0.4693	0.3056	0.3581
n=250	0.3213	0.4095	0.2667	0.3124
n=500	0.2601	0.3315	0.2159	0.2529
n=1000	0.1632	0.2080	0.1354	0.1587

**7- تحليل النتائج:**

- i. عند عدد أبعاد المستهدفة للتقليل (p) تساوي (1,2) وحجم العينة (n) تساوي (1000,500,250,50) و عدد الأبعاد الأصلية للبيانات (10,20,25,35,40) أن طريقة القياس متعدد الأبعاد المترية (Metric MDS) حقق أقل قيم أجهاد من طريقة القياس متعدد الأبعاد باستخدام الشبكات العصبية (NN-MDS).
- ii. ونلاحظ كلما زاد حجم العينة (n) وعدد الأبعاد المستهدفة للتقليل (p) تقل قيمة الأجهاد بنسبة للطريقتين ، ولكن عند زيادة عدد الأبعاد الأصلية للبيانات تزداد قيمة الأجهاد بنسبة للطريقتين .

**8- الاستنتاجات:**

1. أظهرت طريقة القياس متعدد الأبعاد المترية (Metric MDS) أداء متفوقاً على طريقة القياس متعدد الأبعاد باستخدام الشبكات العصبية (NN-MDS) في تقليل الأبعاد.

2. تبين أن زيادة حجم العينة (n) له تأثير إيجابي على أداء كلتا الطريقتين حيث تم ملاحظة انخفاض في قيم الأجهاد مع زيادة حجم العينة (n). هذا يشير إلى أن دقة تمثيل البيانات في الفضاء المنخفض الأبعاد تتحسن مع توفر المزيد من البيانات.

3. لوحظ أيضاً أن زيادة عدد الأبعاد المستهدفة للتقليص (p) من واحد إلى اثنين أدت إلى تحسين أداء الطريقتين.

4. الأبعاد الأصلية للبيانات أدت زيادة عددها (قبل التقليص) إلى ارتفاع قيم الأجهاد لكلا الطريقتين.

#### 9-التوصيات:

1. يوصى بتفضيل استخدام طريقة قياس متعدد الأبعاد المترية (Metric MDS) عند الحاجة إلى تقليص أبعاد البيانات ، خاصة في الحالات المشابهة لسيناريوهات المحاكاة التي تم اختبارها في هذا البحث .

2. يوصى الباحثون بجمع أكبر حجم ممكن من العينات عند تطبيق تقنيات تقليص الأبعاد ، حيث أن ذلك يساهم في تحسين جودة النتائج .

3. عند اختيار عدد الأبعاد المستهدفة ، يجب الموازنة بين الحاجة إلى تبسيط البيانات (أبعاد أقل) والحاجة إلى الحفاظ على دقة التمثيل (قيم أجهاد أقل) .

#### المصادر:

1. Canzar, S., Do, V. H., Jelić, S., Laue, S., Matijević, D., & Prusina, T. (2024). Metric multidimensional scaling for large single-cell datasets using neural networks. \*Algorithms for Molecular Biology\*, \*19\*(21). <https://doi.org/10.1186/s13015-024-00265-3>.
2. Carvajal, S. R. (2024). Simulación. Enfoque. <https://doi.org/10.48204/j.enfoque.v34n30.a4701>.
3. de Leeuw, J. (2000). Multidimensional scaling. \*ResearchGate\*. Retrieved from [https://www.researchgate.net/publication/2634627\\_Multidimensional\\_Scaling](https://www.researchgate.net/publication/2634627_Multidimensional_Scaling).
4. Eraslan, G., Simon, L. M., Mircea, M., Mueller, N. S., & Theis, F. J. (2019). Single-cell RNA-seq denoising using a deep count autoencoder. \*Nature Communications\*, \*10\*(1), 390. <https://doi.org/10.1038/s41467-018-07931-2>.
5. Härdle, W. K., & Simar, L. (2015). Applied multivariate statistical analysis (4th ed.). Springer. <https://doi.org/10.1007/978-3-662-45171-7>.
6. Hout, M. C., Godwin, H. J., Fitzsimmons, G., Robbins, A., Menneer, T., & Goldinger, S. D. (2016). Using multidimensional scaling to quantify similarity in visual search and beyond. \*Attention, Perception, & Psychophysics\*, \*78\*(1), 3–20. <https://doi.org/10.3758/s13414-015-1010-6>.
7. Hryhoruk, P., Khrushch, N., & Grygoruk, S. (2020). Using Multidimensional Scaling for Assessment Economic Development of Regions. \*International Journal of Industrial Engineering & Production Research\*, \*31\*(4), 597–607. <https://doi.org/10.22068/ijiepr.31.4.597>.
8. Hu, J., Li, X., Coleman, K., Schroeder, A., Ma, N., Irwin, D. J., ... & Ren, Y. (2021). SpaGCN: Integrating gene expression, spatial location and histology to identify spatial domains and spatially variable genes by graph convolutional network. \*Nature Methods\*, \*18\*(11), 1342–1351. <https://doi.org/10.1038/s41592-021-01255-8>.
9. Loper, M., & Register, A. H. (2015). Introduction to Modeling and Simulation (pp. 3–16). Springer London. [https://doi.org/10.1007/978-1-4471-5634-5\\_1](https://doi.org/10.1007/978-1-4471-5634-5_1).



10. Markowska, M., Sokolowski, A., & Strahl, D. (2021). Flexible Multidimensional Scaling for Human Smart Development Analysis in EU Countries. \*European Research Studies Journal, 24\*(4), 435–445. <https://doi.org/10.35808/ersj/2582>.
11. org, I., & Groenen, P. J. F. (1997). Modern multidimensional scaling: Theory and applications. Springer. <https://doi.org/10.1007/978-1-4757-2711-1>.
12. Shepard, A. K. Romney, & S. B. Nerlove (Eds.), Multidimensional scaling: Theory and applications in the behavioural sciences (Vol. 1, pp. 179–191). London: Seminar Press.
13. Simulation (pp. 281–292). (2023). Elsevier eBooks. <https://doi.org/10.1016/b978-0-32-399548-1.00020-5>.