



وزارة التعليم العالي والبحث العلمي

جامعة بابل

كلية العلوم الصرفة

(بحث الانحدار الخطي و الشبكات العصبية)

البحث مقدم الى قسم العلوم الصرفة / قسم الرياضيات في كلية التربية
الاساسية جامعة ب متطلبات نيل شهادة البكالوريوس

من قبل الطالبة:

(أنتظار جاسم كوكز)

تحت إشراف:

د. ايناس حمود

٢٠٢٦

١٤٤٧ هـ



بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

{قَالُوا سُبْحَانَكَ لَا عِلْمَ لَنَا إِلَّا مَا عَلَّمْتَنَا
إِنَّكَ أَنْتَ الْعَلِيمُ الْحَكِيمُ}

صدق الله العلي العظيم

البقرة : الآية (32)

الاصراء

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

الحمد لله رب العالمين، والصلاة والسلام على سيدنا محمد وآله الطيبين الطاهرين.

أهدي هذا البحث المتواضع إلى مولاي وسيدي صاحب العصر والزمان، الإمام المهدي (عجل

الله تعالى فرجه الشريف)، نور الله في أرضه، وحجته على عباده، الذي ننتظر ظهوره ليملاً

الأرض قسطاً وعدلاً كما مُننت ظلماً وجوراً.

كما أهديه إلى كل من يسير على نهجه ويتمسك بولايته، وإلى كل قلب مؤمن ينتظر فجر

الظهور، سانلين الله تعالى أن يجعلنا من أنصاره وأعوانه والمستشهادين بين يديه.

وإلى والديّ الكريمين، وزوجي العزيز، وكل من علمني حرفاً، وكان له فضل في دمي

وتشجيعي لإتمام هذا العمل.

راجياً من الله القبول والتوفيق، وأن يكون هذا العمل خالصاً لوجهه الكريم.

شكر وتقدير

الحمد لله الذي بنعمته تتم الصالحات، والصلاة والسلام على أشرف الأنبياء والمرسلين.
أتقدم بجزيل الشكر وعظيم الامتنان إلى كل من ساهم في إنجاز هذا البحث، وأخص بالشكر والتقدير أستاذتي المشرفة (د. ايناس محمود) على توجيهاتها القيمة، ودعمها المستمر، وصبرها في متابعتي خطوة بخطوة حتى إتمام هذا العمل.
كما أتوجه بالشكر إلى أعضاء هيئة التدريس في (جامعة بابل / كلية العلوم الصرفة) على ما قدموه من علم ومعرفة طوال سنوات الدراسة.
ولا يفوتني أن أعبر عن خالص امتناني لعائلتي الكريمة على دعمهم اللامحدود، وتشجيعهم الدائم، ووقوفهم بجانبني في جميع مراحل دراستي.
وأخيراً، أشكر كل من ساهم من قريب أو بعيد في إنجاز هذا البحث.
والحمد لله أولاً وآخراً.

المحتويات


رقم الصفحة	اسم الموضوع	ت
أ	الاية	
ب	الاهداء	
ت	الشكر	
ث	قائمة المحتويات	
	الفصل الاول	
١	مقدمة عامة	١-١
٢	مشكلة البحث	١-٢
٢	اهداف البحث	١-٣
٣	اهمية البحث	١-٤
٣	منهجية البحث	١-٥
٣	هيكلية البحث	١-٦
٤	الفصل الثاني	
٥	مقدمه	٢-١
٧-٥	التعليم الألي	٢-٢
١٢-٧	الأنحدار الخطي	٢-٣
١٩-١٣	الشبكات العصبية الاصطناعية	٢-٤
٢٠	الفصل الثالث	
	مقارنة بين الانحدار الخطي والشبكات العصبية الاصطناعية	٣-١
٢٣-٢٢	عدد المتغيرات والمدخلات	٣-٢
٢٣	القابلية للتفسير	٣-٣
٢٤-٢٣	التعقيد الحسابي	٣-٤
٢٤	حجم البيانات	٣-٥
٢٤	الدقة التنبؤية	٣-٦
٢٤	المرونة وقابلية التوسع	٣-٧
٢٥	متطلبات الافتراضات الإحصائية	٣-٨
٢٥	سرعة التدريب	٣-٩
٢٥	مجالات الاستخدام	٣-١٠
٢٦	الفصل الرابع	
٢٨-٢٧	الاستنتاج	
٣٠-٢٩	قائمة المصادر	

قائمة الاشكال

رقم الصفحة	اسم الشكل	ت
١٦	شكل (١ - ٢) الشبكات لعصبية المتعددت الطبقات	٢-١
١٧	الشكل (٢-٢) الشبكات العصبية الالاتفافية	٢-٢
١٨	الشكل (٣-٢) الشبكات العصبية التكرارية	٢-٣

الفصل الاول

مقدمة عامه



١.١ المقدمة

شهد العالم في العقود الأخيرة تطورًا علميًا وتكنولوجيًا كبيرًا، لا سيما في مجالات الحاسوب والرياضيات التطبيقية، الأمر الذي أدى إلى ظهور تقنيات وأساليب حديثة لمعالجة البيانات وتحليلها. وقد أصبحت البيانات اليوم عنصرًا أساسيًا في مختلف المجالات العلمية والعملية حيث تعتمد الكثير من القرارات على تحليلها وفهم العلاقات التي تربط متغيراتها المختلفة. ومع التقدم الكبير في قدرات الحواسيب، برز مجال الذكاء الاصطناعي بوصفه أحد أهم مجالات البحث العلمي الحديثة، إذ يهدف إلى تطوير أنظمة قادرة على محاكاة بعض القدرات البشرية مثل التعلم، والاستنتاج، واتخاذ القرار. [١]

ويعد تعلم الآلة أحد الفروع الرئيسية للذكاء الاصطناعي، حيث يعتمد على بناء نماذج رياضية قادرة على التعلم من البيانات وتحسين أدائها مع مرور الوقت دون الحاجة إلى برمجة صريحة. ويعتمد تعلم الآلة بشكل أساسي على استخدام الخوارزميات الإحصائية والرياضية لاكتشاف الأنماط والعلاقات بين المتغيرات. ومن بين أبسط هذه الخوارزميات وأكثرها استخدامًا يأتي الانحدار الخطي (**Linear Regression**)، الذي يُستخدم لوصف العلاقة الخطية بين متغير تابع ومتغير مستقل واحد أو أكثر. ويتميز هذا النموذج بالبساطة وسهولة الفهم والتفسير، مما يجعله أداة مناسبة للدراسات الأولية والتحليلات الأساسية.

في المقابل، ظهرت الشبكات العصبية الاصطناعية (**Artificial Neural Networks**) كنماذج أكثر تقدمًا وتعقيدًا، مستوحاة من طريقة عمل الدماغ البشري. إذ تعتمد هذه الشبكات على مجموعة من الوحدات الحسابية المترابطة التي تعمل معًا لمعالجة المعلومات، وتمتلك القدرة على تمثيل العلاقات غير الخطية والمعقدة بين البيانات، وهو ما يجعلها ذات كفاءة عالية في العديد من التطبيقات الحديثة. ومن هذا المنطلق، يسعى هذا البحث إلى تسليط الضوء على كل من الانحدار الخطي والشبكات العصبية الاصطناعية، من خلال دراسة الأسس النظرية التي يقوم عليها كل منهما، وبيان أوجه الاختلاف والتشابه بينهما، مع التركيز على الدور الذي تلعبه النماذج الرياضية في تطوير تقنيات تعلم الآلة وتحليل البيانات. [٢]

١.٢ مشكلة البحث

مع التوسع الكبير في استخدام تقنيات تعلم الآلة، يواجه الباحثون والدارسون تحدياً رئيسياً يتمثل في اختيار النموذج المناسب لتحليل البيانات وبناء التنبؤات الدقيقة. [٢]

فعلى الرغم من بساطة الانحدار الخطي وسهولة تطبيقه، إلا أنه يعتمد على فرضية وجود علاقة خطية بين المتغيرات وهي فرضية قد لا تتحقق في كثير من المشكلات الواقعية. [٣]

من جهة أخرى، تمتلك الشبكات العصبية الاصطناعية قدرة عالية على التعامل مع العلاقات غير الخطية والمعقدة، إلا أن هذا يأتي على حساب زيادة التعقيد الحسابي، وصعوبة تفسير النتائج، بالإضافة إلى الحاجة لاختيار بنية مناسبة للشبكة وعدد الطبقات والعقد، وهو ما قد يمثل عائقاً أمام بعض الباحثين. [٨]

وعليه، تتمثل مشكلة البحث في التساؤل الآتي:

ما مدى كفاءة كل من الانحدار الخطي والشبكات العصبية الاصطناعية في نمذجة العلاقات بين المتغيرات، وما هي المعايير التي يمكن الاعتماد عليها لاختيار النموذج الأنسب؟ كما يسعى البحث إلى الإجابة عن كيفية الموازنة بين البساطة والدقة عند استخدام هذه النماذج في التطبيقات المختلفة.

٣.١ أهداف البحث

يهدف هذا البحث إلى تحقيق مجموعة من الأهداف العلمية، من أهمها:

- تقديم خلفية نظرية واضحة حول مفهوم تعلم الآلة ودوره في تحليل البيانات.
- دراسة الانحدار الخطي من حيث المفهوم والأساس الرياضي وآلية العمل.
- توضيح مفهوم الشبكات العصبية الاصطناعية وبيان مكوناتها الأساسية.
- المقارنة بين الانحدار الخطي والشبكات العصبية من حيث طبيعة العلاقات التي يمكن تمثيلها.
- إبراز أهمية النماذج الرياضية في تطوير تقنيات الذكاء الاصطناعي.
- مساعدة الطلبة والباحثين على فهم الفروقات الجوهرية بين النماذج البسيطة والمتقدمة.

٤.١ أهمية البحث

تتبع أهمية هذا البحث من كونه يتناول موضوعاً يجمع بين الرياضيات والذكاء الاصطناعي، وهما من أكثر المجالات العلمية تطوراً في الوقت الحاضر. إذ يوضح البحث الدور الأساسي للنماذج الرياضية في بناء خوارزميات تعلم الآلة وتحليل البيانات بطريقة علمية دقيقة. [١]

كما تبرز أهمية البحث في كونه يساعد الطلبة على فهم كيفية الانتقال من النماذج الإحصائية التقليدية، مثل الانحدار الخطي، إلى النماذج الحديثة الأكثر تعقيداً، مثل الشبكات العصبية الاصطناعية. ويساهم ذلك في تعزيز القدرة على اختيار النموذج المناسب بناءً على طبيعة المشكلة والبيانات المتاحة. إضافة إلى ذلك، فإن هذا البحث يشكل قاعدة معرفية يمكن الاعتماد عليها في الدراسات المستقبلية، سواء في المجال الأكاديمي أو في التطبيقات العملية، مثل التنبؤ الاقتصادي والتحليل الهندسي، والأنظمة الذكية. [٨]

٥.١ منهجية البحث

يعتمد هذا البحث على المنهج الوصفي التحليلي في عرض المفاهيم النظرية المتعلقة بالانحدار الخطي والشبكات العصبية الاصطناعية، حيث يتم شرح المفاهيم الأساسية وتحليلها بصورة علمية منظمة. كما يعتمد البحث على المنهج المقارن لمقارنة النموذجين من حيث البنية الرياضية، وآلية التعلم، ومستوى الأداء.

٦.١ هيكلية البحث

يتكون هذا البحث من أربعة فصول رئيسية:

الفصل الأول: تناول الإطار العام للبحث، متضمناً المقدمة، ومشكلة البحث، وأهدافه، وأهميته ومنهجيته، وحدوده.

الفصل الثاني: استعرض الإطار النظري للدراسة، حيث ركز على مفاهيم تعلم الآلة، والأسس النظرية للانحدار الخطي والشبكات العصبية الاصطناعية، بالإضافة إلى خوارزميات التحسين وآلية عمل كل نموذج.

الفصل الثالث: خصص لإجراء مقارنة منهجية وتفصيلية بين الانحدار الخطي والشبكات العصبية الاصطناعية من حيث المفهوم الجوهري، وطبيعة العلاقة بين المتغيرات، والتعقيد الحسابي، والقابلية لتفسير النتائج، ومدى دقة التنبؤ لكل منهما.

الفصل الرابع: يتناول عرض النتائج التي تم الحصول عليها من خلال المقارنة بين الانحدار الخطي والشبكات العصبية، مع توضيح الفروقات بينهما من حيث الدقة وطبيعة النتائج، ثم مناقشة هذه النتائج بشكل مبسط وبيان أي النموذجين كان أفضل حسب نوع البيانات، إضافة إلى ذكر أهم الاستنتاجات وبعض التوصيات التي يمكن تنفيذها بالدراسات القادمة.

الفصل الثاني

الانحدار الخطي والشبكة العصبية

٢.١ مقدمة

شهدت السنوات الأخيرة تطورًا هائلًا في مجالات الذكاء الاصطناعي وتعلم الآلة، حيث أصبح بإمكان الحواسيب تحليل كميات ضخمة من البيانات واستخلاص الأنماط والعلاقات المخفية بينها. هذه القدرات مكّنت الباحثين والمهندسين من التنبؤ بالمستقبل واتخاذ قرارات أكثر دقة في مختلف المجالات، بدء من الاقتصاد والطب، مروراً بالهندسة والتسويق، وصولاً إلى علوم البيانات الضخمة. [١]

من أهم النماذج المستخدمة في هذا المجال: **الانحدار الخطي والشبكات العصبية الاصطناعية**. **الانحدار الخطي** يُعد من أبسط النماذج وأكثرها تفسيراً، إذ يصف العلاقة بين المتغيرات بشكل خطي واضح، بينما تمثل **الشبكات العصبية** أداة قوية للتعامل مع العلاقات المعقدة وغير الخطية، مستوحاة من الطريقة التي يعمل بها الدماغ البشري.

٢.٢ التعلم الآلي:

التعلم الآلي (Machine Learning) هو فرع من فروع الذكاء الاصطناعي الذي يتيح للحاسوب اكتساب المعرفة من البيانات دون برمجة صريحة لكل قاعدة. أي أن النظام يتعلم العلاقات والأنماط تلقائياً من البيانات المدخلة، ثم يستخدم هذه المعرفة للتنبؤ أو اتخاذ القرارات. المكونات الأساسية لأي نظام تعلم آلي هي:

١. البيانات (Dataset):

تمثل المدخلات التي سيبنى عليها النموذج، سواء كانت أرقامًا، نصوصًا، صورًا أو إشارات.

٢. النموذج الرياضي (Model):


يمثل العلاقة بين المدخلات والمخرجات.

٣. دالة الخطأ (Loss Function):

تقيس الفرق بين القيم المتوقعة والقيم الحقيقية.

٤. خوارزمية التحسين (Optimization Algorithm):

تهدف لتقليل الخطأ وتحسين أداء النموذج، مثل خوارزمية الانحدار التدرجي [٢]



٢-٢-١ أنواع التعلم الآلي

أ) التعلم الخاضع للإشراف (Supervised Learning)

هو نوع من التعلم يعتمد على بيانات مُعلمة مسبقًا (Labels)، أي أن كل مدخل (Input) يقابله مخرج صحيح معروف. الهدف الأساسي هو تدريب النموذج على فهم العلاقة بين المدخلات والمخرجات بحيث يستطيع التنبؤ بنتائج جديدة بدقة. البيانات مصحوبة بقيمة صحيحة (Labels): النموذج يتعلم من أمثلة جاهزة تحتوي على الإجابة الصحيحة.

الهدف: إيجاد علاقة رياضية بين المدخلات والمخرجات للتنبؤ.

آلية العمل: يتم مقارنة ناتج النموذج مع القيمة الحقيقية وتقليل الخطأ تدريجيًا.

• أمثلة:

< التنبؤ بأسعار الأسهم

< تصنيف الصور إلى فئات محددة

ب) التعلم غير الخاضع للإشراف (Unsupervised Learning)

في هذا النوع لا توجد بيانات مُعلمة، أي أن النموذج لا يعرف النتائج مسبقًا، بل يحاول اكتشاف الأنماط أو العلاقات المخفية داخل البيانات بنفسه.

لا توجد مخرجات معروفة مسبقًا: النموذج يعتمد على البيانات فقط بدون إجابات جاهزة.

الهدف: اكتشاف الأنماط، التجمعات (Clusters)، أو العلاقات داخل البيانات.

آلية العمل: يقوم بتجميع البيانات المتشابهة أو تقليل الأبعاد لفهم الهيكل العام.

• أمثلة:

• تقسيم العملاء إلى مجموعات حسب سلوك الشراء.

• اكتشاف الأنماط في البيانات الطبية أو المالية.

ج) التعلم المعزز (Reinforcement Learning)

يعتمد هذا النوع على مبدأ التجربة والخطأ، حيث يتعلم النموذج من خلال التفاعل مع بيئة معينة ويحصل على مكافآت (Rewards) أو عقوبات (Penalties) حسب أدائه.

يعتمد على التفاعل: النموذج يتخذ قرارات ويلاحظ النتائج.

الهدف: تعظيم المكافآت وتقليل الأخطاء للوصول لأفضل أداء ممكن.

آلية العمل: كل قرار يؤثر على الخطوة التالية، ويتم تحسين السلوك بمرور الوقت.

- أمثلة:
- أنظمة الألعاب (مثل الشطرنج والذكاء الاصطناعي).
- التحكم بالروبوتات والسيارات ذاتية القيادة. [2]

2-3- الانحدار الخطي (Linear Regression)

يُعد الانحدار الخطي أحد الركائز الأساسية في التحليل الإحصائي والنمذجة الكمية، إذ يمثل نقطة الانطلاق لفهم العلاقات بين المتغيرات العددية. تقوم فكرته الجوهرية على دراسة تأثير متغير أو مجموعة متغيرات مستقلة على متغير تابع، ومحاولة تمثيل هذه العلاقة بصيغة رياضية بسيطة يمكن استخدامها في التفسير أو التنبؤ.

تاريخياً، ارتبط ظهور **الانحدار الخطي** بمحاولات علماء الفلك في القرن التاسع عشر لتحليل **أخطاء القياس**، وكان من أبرز من وضع الأساس الرياضي له العالم الألماني Carl Friedrich Gauss عند تطويره لطريقة المربعات الصغرى. ومنذ ذلك الوقت أصبح هذا النموذج أداة تحليلية واسعة الانتشار في العلوم الطبيعية والاجتماعية والهندسية.

الانحدار الخطي نموذج إحصائي لتقدير العلاقة بين متغير تابع **Y** ومتغير مستقل **X**. المعادلة الأساسية:

$$Y = a + bX \dots\dots (1)$$

حيث:

Y = المتغير التابع

X = المتغير المستقل

a = الثابت (الميل عند نقطة الأصل)

b = معامل الانحدار [٥]

تكم أهمية الانحدار الخطي في جانبين رئيسيين:

التفسير الكمي: إذ يسمح بقياس مقدار التغير المتوقع في المتغير التابع نتيجة تغير وحدة واحدة في المتغير المستقل.

التنبؤ: إذ يمكن استخدام المعادلة الناتجة لتقدير قيم مستقبلية.

كما يتميز النموذج ببساطته الرياضية، مما يجعله قابلاً للتطبيق حتى في حالات البيانات محدودة الحجم، إضافة إلى إمكانية تحليله جبرياً وإحصائياً دون الحاجة إلى خوارزميات معقدة [٣].

2-3-2 أنواع الانحدار الخطي

ينقسم الانحدار الخطي حسب عدد المتغيرات المستقلة إلى قسمين:

أولاً: الانحدار الخطي البسيط

في هذا النوع يكون لدينا متغيران أحدهما تابع والآخر مستقل والعلاقة بينهما خطية. ويستخدم للتنبؤ بقيم المتغير التابع بدلاً من المتغير المستقل فمثلاً قد يرغب باحث في تحديد شكل العلاقة بين وزن الطفل (متغير تابع) وعمره (متغير مستقل)، العلاقة بين حجم سلعة ما (متغير تابع) وحجم مصروفات الدعاية (متغير مستقل) العلاقة بين مستوى الأداء الوظيفي (متغير تابع) والمؤهل الأكاديمي (متغير مستقل) ... الخ. كتاب تحليل الانحدار الخطي

أي ان قيمة لا تتغير تبعاً لتغير قيمة x ولكن هذه المعادلة لا تحدد شكل العلاقة بين المتغيرين، فقد تكون الدالة على صورة خطية أو منحنى آخر، ويعتمد تحديد صيغة الدالة على الباحث وذلك بوضع افتراضات حول هذه العلاقة [٦].

فمثلا قد يفترض باحث أن هناك علاقة خطية بين الادخال وسعر الفائدة وبهذا التقريب لشكل الدالة يمكن ان تأخذ المعادلة صيغة الدالة الخطية التالية:

$$Y_i = \beta_0 + \beta_1 X_i \quad (2)$$

Constant/Intercept
Independent Variable
↓
↓
↑
↑
Dependent Variable
Slope/Coefficient

ثانيا: الانحدار الخطي المتعدد

الانحدار المتعدد (متغيرين مستقلين أو أكثر)، تحليل الانحدار ملائم لمعرفة كم من التباين يستطيع المتغيران معا أن يفسر أنه من التباين في المتغير التابع. و المعرفة بتباين المقدار الذي يشرحه المتغير الأول ومعرفة تباين المقدار الذي يشرحه المتغير [٦] الثاني نستطيع أن نكشف عن الأهمية لكل من المتغيرين .

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$

في الانحدار المتعدد نفترض أن لدينا متغيرا تابعا واحدا ترمز له بالرمز Y ومجموعة من المتغيرات المستقلة عددها m متغيرا وترمز لها بالرمز X_1, X_2, \dots, X_m كحالة خاصة في الانحدار البسيط يكون $m = 1$

تريد هنا الحصول على أفضل معادلة انحدار تمثل العلاقة بين المتغير التابع والمتغيرات المستقلة وذلك إذا توافرت لدينا بيانات من عينة حجمها فيكون النموذج الرياضي الخطي هو:

(Y_i) المتغير المعتمد أو متغير الاستجابة .

(X_i) المتغيرات المستقلة أو المتغير التفسيري (التوضيحي) .

(B_k) تمثل معالم النموذج المجهولة، وهي تمثل مقدار التغير في Y للتغير بوحدة واحدة من X_i مع ثبات بقية المتغيرات المستقلة .

(u_i) قيمة المتغير العشوائي المجهولة، والتي لها توزيع طبيعي بمتوسط صفر وتباين σ^2 علماً أن قيم المشاهدة (١) تكون لكل (١، ٢، ٣،)

$$bmxm..... + b3x3+ya+b1x1 + b2x2 \quad (3)$$

وإجمالاً فإن معادلة الانحدار الخطي المتعدد في العينات

a: المقطع الصادي، وهو بعد النقطة التي يقطع عندها خط الانحدار

B1 معامل الانحدار للمتغير الأول x_1 وزن الانحدار، الانحدار في والذي يمكن تغييره x_1 وحدة واحدة مع امتداد ترابط الانحدار الخطي.

B2 معامل الانحدار للمتغير الثاني x_2 وزن الانحدار، الانحدار في والذي يمكن تغييره x_2 وحدة واحدة مع امتداد ترابط الانحدار الخطي.

انواع الانحدار الخطي المتعدد :

● **الانحدار المعياري :** في هذه الطريقة ندخل المتغيرات المستقلة في معادلة الانحدار دفعة واحدة لنحصل على المعادلة التي تصف العلاقة بين كل المتغيرات المستقلة والمتغير التابع مرة واحدة دون مناقشة هل كل المتغيرات المستقلة يجب أن تدخل في المعادلة أم لا؟ ولا نتعرض لمناقشة هل المتغيرات المستقلة مرتبطة بعضها البعض أم مستقلة. [٨]

● **الانحدار الهرمي :** في الانحدار الهرمي تدخل المتغيرات المستقلة في المعادلة المقترحة تباعاً وتحدد ترتيب دخول هذه المتغيرات في المعادلة المقترحة على أساس إحصائي نظري

- **الانحدار التدريجي** : في نموذج الانحدار المتدرج عدد المتغيرات المستقلة المدخلة في النموذج وكذلك ترتيب إدخالها يحدد من خلال معيار إحصائي يتم الوصول إليه عن طريق إجراء الانحدار المتدرج

2-3-3 مشتقات المربعات الصغرى

لحساب المعاملات المثلى، نستخدم طريقة المربعات الصغرى لتقليل مجموع مربعات الأخطاء:

$$S = \sum_{i=1}^m (Y_i - \hat{Y}_i)^2 \dots\dots (4)$$

نقوم باشتقاق S بالنسبة لكل معامل ومساواته بالصفر للحصول على القيم المثلى. [3]

استكمالاً لما تم عرضه في مشتقات المربعات الصغرى، فإن مساواة المشتقات بالصفر تؤدي إلى الحصول على نظام من المعادلات الخطية يُعرف بالمعادلات الطبيعية، والتي تُستخدم لإيجاد القيم المثلى لمعاملات الانحدار. ويُظهر هذا الأسلوب أن الحل يعتمد على العلاقة بين المتغيرات، مما يعزز دقة النموذج في تمثيل البيانات.

كما يمكن تفسير طريقة المربعات الصغرى هندسياً على أنها إيجاد أفضل خط مستقيم يحقق أقل مجموع ممكن من مربعات الأخطاء بين القيم الحقيقية والمتوقعة. [4]

2-3-4 خوارزمية الانحدار التدرجي (Gradient Descent)

- نبدأ بقيم عشوائية للمعاملات.
- نحدث المعاملات باستخدام:

$$\theta_{new} = \theta_{old} - \alpha \frac{\partial J}{\partial \theta} \dots\dots(5)$$

- دالة الخطأ = J ، معدل التعلم = a

استنادًا إلى ما سبق في خوارزمية الانحدار التدريجي، يتم تحديث معاملات النموذج بشكل تكراري باتجاه تقليل دالة الخطأ، حيث يتم التحرك بعكس اتجاه المشتقة للوصول إلى الحل الأمثل.

وتتأثر كفاءة هذه الخوارزمية بعوامل عدة، من أهمها معدل التعلم وتهيئة البيانات، إذ أن اختيار قيمة غير مناسبة قد يؤدي إلى بطء التقارب أو عدم استقرار النتائج.

كما يتم اعتماد شرط إيقاف معين، مثل الوصول إلى عدد محدد من التكرارات أو عندما يصبح التغيير في الخطأ ضئيلاً جدًا. [٢]

2-3-5 مزايا وعيوب الانحدار الخطي

من مزايا الانحدار الخطي:

- بسيط وسهل التفسير
- سريع التنفيذ

أما عيوب الانحدار الخطي:

- يفترض علاقات خطية فقط
- حساس للقيم الشاذة [٣]

2-3-6 التطبيقات العلمية للانحدار الخطي

يُستخدم الانحدار الخطي في العديد من المجالات العلمية، منها:

الاقتصاد: التنبؤ بالأسعار والدخل والطلب.

الهندسة: تحليل العلاقات الفيزيائية.

الطب: تحليل المتغيرات الصحية.

العلوم الاجتماعية: دراسة السلوكيات والظواهر الاجتماعية.

الذكاء الاصطناعي: كنموذج أساس في بناء الخوارزميات التنبؤية. [٧]

4-2 الشبكات العصبية الاصطناعية (Artificial Neural Networks)

2-4-1 مفهوم الشبكات العصبية الاصطناعية

تُعدّ الشبكات العصبية الاصطناعية من أهم نماذج الذكاء الاصطناعي المعاصرة، إذ استلهم تصميمها من البنية الوظيفية للدماغ البشري والجهاز العصبي. فالدماغ يتكوّن من بلايين الخلايا العصبية التي تتواصل فيما بينها عبر إشارات كهربائية وكيميائية، وتقوم بعمليات معقدة مثل التفكير، والتعلم، واتخاذ القرار، والتعرف على الأنماط.[٩]

وبطريقة مشابهة، تعتمد الشبكات العصبية الاصطناعية على مجموعة من الوحدات الحسابية الصغيرة تُسمّى (Neurons) أو العقد العصبية، ترتبط فيما بينها بروابط تمثل الأوزان (Weights)، وتقوم هذه الوحدات بمعالجة البيانات المدخلة وتحويلها تدريجياً إلى مخرجات ذات معنى.

الشبكة العصبية ليست برنامجاً ثابتاً، بل نظام قابل للتعلم، أي أنها تستطيع تحسين أدائها بمرور الوقت من خلال التدريب على البيانات. ويتم ذلك عبر تعديل الأوزان والانحيازات (Bias) بناءً على مقدار الخطأ بين الناتج الفعلي والناتج المتوقع، مما يجعل النموذج أكثر دقة في التنبؤ أو التصنيف.[١٠]

تستخدم الشبكات العصبية في مجالات متعددة مثل:

- التعرف على الصور والوجوه
- التعرف على الكلام ومعالجة اللغة الطبيعية
- التنبؤ بالأسعار والأسواق
- الأنظمة الطبية الذكية
- الأنظمة الهندسية والتحكم الذكي

2-4-2 البنية العامة للشبكات العصبية

تتكون الشبكة العصبية الاصطناعية من عدة طبقات رئيسية:

١. طبقة الإدخال (Input Layer)

تمثل هذه الطبقة نقطة دخول البيانات إلى الشبكة، حيث يتم إدخال القيم الرقمية للمتغيرات (Features). كل عقدة في هذه الطبقة تمثل متغيراً واحداً من متغيرات البيانات.

٢. الطبقات المخفية (Hidden Layers)

وهي الطبقات التي تقوم بالمعالجة الفعلية للبيانات، حيث يتم فيها تنفيذ العمليات الرياضية وتحويل المدخلات إلى تمثيلات أكثر تجريداً. وقد تحتوي الشبكة على طبقة مخفية واحدة أو عدة طبقات، وكلما زاد عدد الطبقات زادت قدرة النموذج على تمثيل العلاقات المعقدة بين المتغيرات.

٣. طبقة الإخراج (Output Layer)

تعتبر هذه الطبقة هي المرحلة النهائية في الشبكة العصبية، ومهمتها الأساسية هي تقديم النتيجة النهائية أو "التنبؤ" الذي وصلت إليه الشبكة بعد معالجة البيانات في الطبقات السابقة.

تمثل ناتج الشبكة العصبية، وقد تكون:

- قيمة عددية (في مسائل الانحدار والتنبؤ)
- فئة أو تصنيف (في مسائل التصنيف) [١١]

2-4-3 النموذج الرياضي للخلية العصبية

تُعد الخلية العصبية الوحدة الأساسية في الشبكة العصبية، وتعتمد في عملها على عملية رياضية بسيطة لكنها فعّالة، حيث يتم حساب الناتج وفق المعادلة: [١٢]

تعكس هذه المعادلة فكرة الجمع الموزون للمدخلات ثم تمرير الناتج عبر دالة غير خطية لإنتاج المخرج النهائي.

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right) \dots\dots\dots (6)$$

2-4-4 دوال التفعيل (Activation Functions)

تلعب دوال التفعيل دوراً محورياً في الشبكات العصبية، إذ تُكسب النموذج القدرة على تمثيل العلاقات غير الخطية. ومن أشهر هذه الدوال:

١. دالة Sigmoid

تُستخدم بشكل واسع في النماذج الكلاسيكية، وتحوّل القيم إلى مجال محصور بين (٠ و ١)، وتُستخدم غالباً في مسائل التصنيف الثنائي.

٢. دالة Tanh

تشبه دالة Sigmoid لكنها تُخرج قيماً بين (-١ و ١+)، مما يساعد في تحسين استقرار التعلم.

٣. دالة ReLU

وهي الأكثر استخداماً في الشبكات العميقة الحديثة، وتتميّز بالبساطة والكفاءة الحسابية، وتُعرّف بالعلاقة:

$$\text{ReLU}(x) = \max(0, x)$$

[١٣]

2-4-5 آلية التعلم في الشبكات العصبية

تعتمد الشبكات العصبية على ما يُعرف بخوارزمية الانتشار العكسي (Backpropagation)، وهي خوارزمية تقوم على:

١. تمرير البيانات من طبقة الإدخال إلى الإخراج (Forward Propagation)

٢. حساب الخطأ بين الناتج الحقيقي والناتج المتوقع

٣. إعادة توزيع الخطأ على الأوزان

٤. تعديل الأوزان باستخدام خوارزميات التحسين مثل Gradient Descent


تهدف هذه العملية إلى تقليل دالة الخطأ (Loss Function) تدريجياً حتى الوصول إلى نموذج مستقر ودقيق. [١٤]

2-4-6 أنواع الشبكات العصبية الاصطناعية

١. الشبكات العصبية متعددة الطبقات (MLP)

تعد هذه الشبكات النوع الأساسي والتقليدي (Feed-forward)، وتتكون من طبقة إدخال، وطبقات مخفية (Hidden Layers)، وطبقة مخرجات.

- آلية العمل: تنتقل البيانات فيها باتجاه واحد من المدخلات إلى المخرجات، حيث تقوم كل طبقة باستخلاص الميزات ومعالجتها عبر أوزان (Weights) محددة.
- الاستخدامات: تُستخدم بكثافة في المهام التي تعتمد على البيانات الجدولية (Structured Data)، مثل التصنيف (Classification) والتنبؤ (Prediction).




شكل (1-2) الشبكات لعصبية المتعددت الطبقات

٢. الشبكات العصبية الالتفافية (CNN)

هي شبكات متخصصة في معالجة البيانات التي تمتلك بنية مكانية أو شبكية، وتعتبر الثورة الحقيقية في مجال الرؤية الحاسوبية.

- آلية العمل: تعتمد على استخدام "المرشحات" (Filters) التي تقوم بعملية الالتفاف (Convolution) لاستخراج الأنماط من الصور بشكل آلي (مثل الحواف، الألوان، ثم الأجسام الكاملة).
- الاستخدامات: تُستخدم في معالجة الصور، الرؤية الحاسوبية، والتعرف على الأنماط البصرية في الفيديوهات.




الشكل (2-2) الشبكات العصبية الالتفافية

٣. الشبكات العصبية التكرارية (RNN)

تختلف هذه الشبكات عن سابقتها بوجود "حلقات تكرار" تسمح للمعلومات بالبقاء، مما يجعلها تمتلك نوعاً من الذاكرة قصيرة المدى.

- آلية العمل: تعالج البيانات المتسلسلة بحيث يعتمد مخرج اللحظة الحالية على المدخلات الحالية وما تم تعلمه من المدخلات السابقة.
- الاستخدامات: تُستخدم في معالجة البيانات الزمنية (Time Series) والنصوص، مثل الترجمة الآلية، التعرف على الكلام، وتوقع تقلبات الأسواق المالية. [١٣]



الشكل (2-3) الشبكات العصبية التكرارية

2-4-7 مزايا الشبكات العصبية

- القدرة العالية على التعلم من البيانات
- تمثيل العلاقات غير الخطية المعقدة
- المرونة في التعامل مع أنواع مختلفة من البيانات [٤]

2-4-8 التحديات والقيود

- الحاجة إلى بيانات كبيرة
- التعقيد الحسابي العالي
- صعوبة تفسير النتائج (Black Box) [٨]

2-4-9 التطبيقات العملية للشبكات العصبية

تُستخدم الشبكات العصبية الاصطناعية بشكل واسع في التطبيقات الواقعية، ولم تعد محصورة في الجانب النظري فقط، بل أصبحت جزءاً أساسياً من الأنظمة الذكية الحديثة، ومن أبرز هذه التطبيقات:

١. **القطاع الطبي:** تُستخدم في تشخيص الأمراض، تحليل الصور الطبية، التنبؤ بالأمراض المزمنة، واكتشاف الأورام.

٢. **الهندسة:** تدخل في أنظمة التحكم الذكي، الروبوتات، تحليل الأنظمة المعقدة، ومعالجة الإشارات.

٣. **الاقتصاد والمال:** التنبؤ بالأسعار، تحليل الأسواق المالية، تقييم المخاطر الائتمانية.

٤. **الأمن والمعلومات:** التعرف على الوجوه، أنظمة المراقبة الذكية، كشف الاحتيال.

٥. **التعليم:** الأنظمة التعليمية الذكية والتعلم التكيفي.[٢]

2-4-10 مقارنة منهجية بين الشبكات العصبية والنماذج التقليدية

تتميز الشبكات العصبية عن النماذج الإحصائية التقليدية بعدة جوانب:

- النماذج التقليدية تعتمد على افتراضات رياضية محددة (كالخطية والتوزيع الطبيعي).
- الشبكات العصبية لا تتطلب افتراضات صارمة حول شكل العلاقة بين المتغيرات.
- النماذج التقليدية سهلة التفسير.
- الشبكات العصبية قوية في التنبؤ ولكن تفسير نتائجها أصعب.

وهذا يجعل الشبكات العصبية مناسبة للأنظمة المعقدة، في حين تبقى النماذج التقليدية مناسبة للأنظمة البسيطة.[١٥]

الفصل الثالث

مقارنة بين الانحدار الخطي والشبكات العصبية الاصطناعية

3-1 مقارنة بين الانحدار الخطي والشبكات العصبية الاصطناعية

تُعد كل من طريقة الانحدار الخطي (Linear Regression) والشبكات العصبية الاصطناعية (Artificial Neural Networks) من أهم الأساليب المستخدمة في تحليل البيانات وبناء النماذج التنبؤية في مختلف المجالات العلمية والاقتصادية والهندسية. وعلى الرغم من اشتراك الطريقتين في هدفهما الأساسي والمتمثل في التنبؤ بالقيم المستقبلية أو تفسير العلاقات بين المتغيرات، إلا أن الاختلاف بينهما يظهر بصورة واضحة من حيث الأساس النظري، وآلية العمل، وطبيعة العلاقة التي يمكن تمثيلها، ومستوى التعقيد الحسابي، وكذلك القدرة التفسيرية.

في هذا المطلب سيتم إجراء مقارنة علمية مفصلة بين الطريقتين من عدة جوانب أساسية. [١٦]

3-1-1 يستخدم الانحدار الخطي في كل من:

- كانت العلاقة بين المتغيرات واضحة وبسيطة (مثل كلما زاد الإنفاق على الإعلانات زادت المبيعات).
- كان حجم البيانات المتاح لديك صغيراً.
- كان من الضروري أن تشرح لماذا أعطى النموذج هذه النتيجة (الشفافية).

اما الشبكة العصبية تستخدم في كل من:

- كانت البيانات غير منظمة مثل الصور النصوص، أو الأصوات
- كانت العلاقة بين المدخلات والمخرجات شديدة التعقيد ولا تتبع نمطاً خطياً.
- كانت دقة التنبؤ هي الأولوية القصوى ولا يهم فهم كيفية عمل النموذج داخلياً. [١٧]

3-1-2 طبيعة العلاقة بين المتغيرات

من المثير للاهتمام معرفة أن الانحدار الخطي هو في الواقع أبسط شكل من أشكال الشبكات العصبية. فإذا قمت ببناء شبكة عصبية مكونة من "عصبون" واحد فقط وبدون "دالة تنشيط" (Activation Function) ستحصل رياضياً على نموذج انحدار خطي تماماً.

يُعد الفرق الجوهرى بين الانحدار الخطي والشبكات العصبية الاصطناعية هو طبيعة العلاقة التي يمكن لكل منهما تمثيلها.

أولاً: الانحدار الخطي

يعتمد الانحدار الخطي على افتراض أساسي مفاده أن العلاقة بين المتغير التابع والمتغيرات المستقلة علاقة خطية يمكن تمثيلها بمعادلة رياضية من الدرجة الأولى بالشكل:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \epsilon \quad (7)$$

وهذا يعني أن تأثير أي متغير مستقل على المتغير التابع يكون تأثيراً ثابتاً ومباشراً. فإذا زادت قيمة المتغير المستقل بمقدار وحدة واحدة، فإن المتغير التابع يتغير بمقدار ثابت يساوي قيمة المعامل.

وعليه، فإن الانحدار الخطي يكون مناسباً في الحالات التي تكون فيها العلاقة بين المتغيرات واضحة وبسيطة، ولا تحتوي على تعقيد أو تداخل غير خطي.

ثانياً: الشبكات العصبية الاصطناعية

على عكس الانحدار الخطي، لا تفترض الشبكات العصبية وجود علاقة خطية محددة مسبقاً. بل إنها قادرة على تمثيل العلاقات الخطية وغير الخطية على حد سواء، وذلك من خلال الطبقات المخفية ودوال التنشيط غير الخطية مثل:

- Sigmoid
- Tanh
- ReLU

إن وجود هذه الدوال يسمح للنموذج باكتشاف أنماط معقدة وتفاعلات متعددة بين المتغيرات، مما يجعل الشبكات العصبية أكثر مرونة عند التعامل مع البيانات الواقعية التي غالباً ما تكون غير خطية بطبيعتها. [٨]

3-2 عدد المتغيرات والمدخلات

الانحدار الخطي

يمكن للانحدار الخطي التعامل مع عدة متغيرات مستقلة، ويُعرف في هذه الحالة بالانحدار الخطي المتعدد. إلا أن زيادة عدد المتغيرات قد تؤدي إلى مشاكل مثل:

- التعدد الخطي (Multicollinearity)
- زيادة التباين
- انخفاض دقة التقدير

كما أن النموذج يصبح أكثر حساسية لوجود علاقات قوية بين المتغيرات المستقلة.

الشبكات العصبية

الشبكات العصبية قادرة على التعامل مع عدد كبير من المدخلات دون الحاجة إلى افتراضات إحصائية صارمة. كما يمكنها استخراج الخصائص المهمة تلقائيًا من البيانات، خاصة في التطبيقات التي تتضمن بيانات كبيرة أو عالية الأبعاد. [٥]

3-3 القابلية للتفسير

الانحدار الخطي

من أهم مزايا الانحدار الخطي أنه يتمتع بدرجة عالية من القابلية للتفسير. حيث يمكن تحليل كل معامل على حدة، ومعرفة:

- اتجاه العلاقة (موجب أو سالب)
- قوة التأثير
- معنوية التأثير إحصائيًا

وهذا يجعله مناسبًا في الدراسات التي تهدف إلى تفسير العلاقة وليس فقط التنبؤ.

الشبكات العصبية

تُعرف الشبكات العصبية بأنها نموذج "الصندوق الأسود"، وذلك لصعوبة تفسير كيفية وصول النموذج إلى النتيجة النهائية، خاصة عند زيادة عدد الطبقات المخفية.

فعلى الرغم من دقتها العالية، إلا أن فهم تأثير كل متغير داخل الشبكة ليس أمرًا مباشرًا. [١٢]

3-4 التعقيد الحسابي

الانحدار الخطي

يتميز ببساطة رياضية واضحة، حيث يمكن تقدير المعاملات باستخدام طريقة المربعات الصغرى (OLS)، والتي تمتلك حلاً تحليليًا مباشرًا.

زمن التنفيذ قليل نسبيًا، ولا يتطلب موارد حاسوبية كبيرة.

الشبكات العصبية

تتطلب عمليات حسابية متكررة أثناء التدريب، خاصة في خوارزمية الانتشار العكسي، حيث يتم:

- حساب الخطأ
- نشره عكسيًا
- تحديث الأوزان
- تكرار العملية لعدد كبير من الدورات

كل ذلك يؤدي إلى زيادة زمن التدريب والحاجة إلى موارد حاسوبية أعلى.

3-5 حجم البيانات

الانحدار الخطي يعمل بكفاءة مع أحجام بيانات صغيرة ومتوسطة.

أما الشبكات العصبية فتزداد كفاءتها كلما زاد حجم البيانات، حيث تعتمد على التعلم من أنماط متعددة ومتكررة. [١٦]

3-6 الدقة التنبؤية

في حالة وجود علاقة خطية واضحة، غالبًا ما يعطي الانحدار الخطي نتائج دقيقة ومقبولة.

أما في حالة وجود علاقات معقدة وغير خطية، فإن الشبكات العصبية تتفوق عادة في الدقة التنبؤية. [١١]

3-7 المرونة وقابلية التوسع

الانحدار الخطي محدود نسبيًا من حيث المرونة.

بينما الشبكات العصبية يمكن تطويرها إلى نماذج أعمق وأكثر تعقيدًا (Deep Learning)، مما يمنحها قابلية توسع عالية.

3-8 متطلبات الافتراضات الإحصائية

الانحدار الخطي يعتمد على عدة افتراضات:

- التوزيع الطبيعي للبواقي
- ثبات التباين
- استقلالية الأخطاء

أما الشبكات العصبية فلا تعتمد على افتراضات إحصائية صارمة. [١٤]

3-9 سرعة التدريب

الانحدار الخطي سريع جدًا في التدريب.

الشبكات العصبية أبطأ نسبيًا، خاصة عند وجود عدد كبير من الطبقات. [٩]

3-10 مجالات الاستخدام

الانحدار الخطي يُستخدم في:

- الدراسات الاقتصادية
- البحوث الإدارية
- التحليلات الإحصائية التقليدية

الشبكات العصبية تُستخدم في:

- التعرف على الصور
- معالجة اللغة الطبيعية
- التنبؤ المالي
- الأنظمة الذكية [17]

الفصل الرابع

الاستنتاج

الاستنتاج:

بعد استعراض المقارنة التفصيلية بين الانحدار الخطي والشبكات العصبية الاصطناعية، يمكن القول إن كلا النموذجين يعدان من أهم الأدوات المستخدمة في مجال تحليل البيانات والتنبؤ، إلا أن طبيعة استخدام كل منهما تختلف تبعاً لطبيعة المشكلة والبيانات المتاحة وأهداف الدراسة.

الانحدار الخطي يعد من أقدم وأكثر الأساليب الإحصائية استخداماً، ويتميز بالبساطة وسهولة التطبيق والتفسير. يعتمد هذا النموذج على افتراض وجود علاقة خطية مباشرة بين المتغيرات المستقلة والمتغير التابع، مما يجعله مناسباً للحالات التي تكون فيها العلاقات واضحة وغير معقدة. كما أن نتائجه قابلة للتفسير بسهولة، حيث يمكن تحديد مقدار تأثير كل متغير مستقل على المتغير التابع من خلال قيمة المعامل المرتبط به، وهذا يمنح الباحث قدرة عالية على فهم طبيعة العلاقة وتحليلها علمياً.

إضافة إلى ذلك، يتميز الانحدار الخطي بسرعة التنفيذ وانخفاض التكلفة الحسابية، إذ لا يحتاج إلى موارد حاسوبية كبيرة أو زمن تدريب طويل، مما يجعله مناسباً للبيانات الصغيرة أو الدراسات التي تتطلب تحليلاً مباشراً وسريعاً. ومع ذلك، فإن من أبرز قيوده عدم قدرته على تمثيل العلاقات غير الخطية بشكل مباشر، فضلاً عن تأثره بالمشكلات الإحصائية مثل التداخل الخطي بين المتغيرات المستقلة أو وجود القيم الشاذة.

في المقابل، تمثل الشبكات العصبية الاصطناعية تطوراً حديثاً في مجال النمذجة والتعلم الآلي، وهي مستوحاة من آلية عمل الدماغ البشري في معالجة المعلومات. تمتاز هذه الشبكات بقدرتها العالية على تمثيل العلاقات المعقدة وغير الخطية من خلال الطبقات المخفية ودوال التنشيط المختلفة، وهذا يمنحها مرونة كبيرة في التعامل مع البيانات ذات الأنماط غير الواضحة أو التي تحتوي على تداخلات متعددة بين المتغيرات. ومن أهم مزايا الشبكات العصبية قدرتها على التعلم من البيانات وتحسين أدائها تدريجياً من خلال خوارزمية الانتشار العكسي، حيث يتم تعديل الأوزان الداخلية لتقليل الخطأ بين القيم الحقيقية والمتوقعة. كما أنها قادرة على التعامل مع كميات كبيرة من البيانات ذات الأبعاد العالية، وهو ما يجعلها مناسبة للتطبيقات الحديثة مثل التنبؤ المالي، تحليل الصور، معالجة اللغة الطبيعية، والأنظمة الذكية.

إلا أن هذه القوة تقابلها بعض التحديات، من أبرزها ارتفاع التعقيد الحسابي والحاجة إلى بيانات تدريب كبيرة نسبياً للحصول على نتائج دقيقة. كما أن الشبكات العصبية توصف غالباً بأنها "صندوق أسود"، نظراً لصعوبة تفسير طريقة اتخاذها للقرار أو تحديد التأثير الفردي لكل متغير، وهو ما قد يُعد عائقاً في الدراسات التي تتطلب تفسيراً إحصائياً واضحاً للنتائج.

ومن خلال المقارنة بين النموذجين، يتضح أن الاختيار بين الانحدار الخطي والشبكات العصبية لا يعتمد على كون أحدهما أفضل بشكل مطلق، وإنما يعتمد على طبيعة المشكلة البحثية. فإذا كانت العلاقة بين المتغيرات بسيطة وخطية، وكان الهدف هو التفسير والتحليل الإحصائي، فإن الانحدار الخطي يكون الخيار الأنسب. أما إذا كانت البيانات معقدة، أو تحتوي على أنماط غير خطية، أو كان الهدف هو الحصول على أعلى دقة تنبؤية ممكنة، فإن الشبكات العصبية تُعد الخيار الأكثر ملاءمة.

كما يجب الأخذ بنظر الاعتبار حجم البيانات وجودتها، إذ إن الشبكات العصبية تُظهر أداءً أفضل كلما زادت كمية البيانات المتاحة، في حين أن الانحدار الخطي يمكن أن يعطي نتائج جيدة حتى مع عينات صغيرة نسبياً. كذلك فإن توفر الإمكانيات الحاسوبية والخبرة التقنية يلعب دوراً مهماً في تحديد النموذج المناسب.

بناءً على ما سبق، يمكن القول إن كلا النموذجين يمثلان أدوات مكملة لبعضهما البعض في مجال تحليل البيانات. فالانحدار الخطي يوفر البساطة والوضوح وسهولة التفسير، بينما توفر الشبكات العصبية القدرة على التعامل مع التعقيد والأنماط غير الخطية. وعليه، فإن الاستخدام الأمثل لأي منهما يتطلب فهماً عميقاً لطبيعة البيانات وأهداف الدراسة والقيود العملية المتاحة.

وفي إطار التطور السريع لتقنيات الذكاء الاصطناعي، أصبحت الشبكات العصبية تحتل مكانة متقدمة في التطبيقات الحديثة، إلا أن ذلك لا يقلل من أهمية الانحدار الخطي الذي ما يزال يُستخدم على نطاق واسع في البحوث الأكاديمية والدراسات التطبيقية. ومن هنا يمكن التأكيد على أن التكامل بين الأساليب الإحصائية التقليدية وتقنيات التعلم الآلي يمثل الاتجاه الأمثل لتحقيق نتائج دقيقة وموثوقة في تحليل البيانات.

وفي الختام، فإن المقارنة بين الانحدار الخطي والشبكات العصبية تُبرز الفروق الجوهرية بين النماذج الإحصائية التقليدية والنماذج المعتمدة على التعلم الآلي، وتوضح أن التطور التكنولوجي لا يعني الاستغناء عن الأساليب الكلاسيكية، بل توظيفها بالشكل المناسب ضمن سياق علمي مدروس يحقق أفضل النتائج الممكنة.

المصادر:

- [1] Gauss, C. F. (2012). Theoria Motus Corporum Coelestium in Secionibus Conicis Solem Ambientium (Foundations of Least Squares Method).
- [2] Ismail, M. A. R. (2016). Linear Regression Analysis. Riyadh.
- [3] Questioner. Regression Analysis: A Comprehensive Guide. Questioner Website.
- [4] Al-Qahtani, S. S. (2015). Applied Statistics. Riyadh.
- [5] Al-Tamimi, K. I. Statistical Analysis and Linear Regression. Dar Al-Maseera for Publishing and Distribution, Jordan.
- [6] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- [7] Haykin, S. (2009). Neural Networks and Learning Machines (3rd ed.). Pearson Education.
- [8] Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
- Russell, S., & Norvig, P. (2021). Artificial Intelligence: A Modern Approach. Pearson.
- [9] Aggarwal, C. C. (2018). Neural Networks and Deep Learning. Springer.
- [10] Nielsen, M. (2015). Neural Networks and Deep Learning. Determination Press.
- [11] Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial Neural Networks: A Tutorial. IEEE Computer.
- [12] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Representations by Back-Propagating Errors. Nature.
- [13] Krose, B., & Smagt, P. (1996). An Introduction to Neural Networks. University of Amsterdam.

[14] Mitchell, T. M. (1997). Machine Learning. McGraw-Hill.

[15] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. Nature, 521(7553), 436–444.

[16] Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). Introduction to Linear Regression Analysis (5th ed.). Wiley.