

تحسين تشفير البيانات باستخدام الشبكات العصبية التوليدية

د. ياسر الملك أحمد سليمان

قسم علوم الحاسوب نظم المعلومات، الجامعة التكنولوجية (السودان)

Improving Data Encryption with Generative Adversarial Networks (GANs)**Dr. YasserElmalik Ahmed Seleman**<https://orcid.org/0009-0007-2052-0408>

Department of Computer Science and Information Systems, University of Technology (Sudan),

dr.yaserking359@hotmail.com

تاريخ الاستلام: 2025/08/03 تاريخ القبول: 2025/09/16 تاريخ النشر: 2025/12/01

الملخص:

تناول الورقة أهمية حماية البيانات في العصر الرقمي، حيث تتعرض المعلومات الحساسة لهجمات متزايدة من الهجمات السيبرانية، يعد التشفير أحد الأساليب الأساسية لحماية هذه البيانات، ولكن التحديات المتعلقة بالأمان وكفاءة الأداء تظل قائمة في هذا السياق، تبرز الشبكات العصبية التوليدية كأداة مبتكرة لتعزيز تقنيات التشفير.

الشبكات العصبية التوليدية على فكرة وجود نموذجين: المولد الذي يسعى لإنشاء بيانات جديدة، والمميز الذي يهدف إلى التمييز بين البيانات الحقيقية والمزيفة. من خلال هذه العملية التنافسية، يمكن للشبكات العصبية التوليدية تحسين جودة البيانات المولدة ومن أشهر تطبيقاتها توليد مفاتيح تشفير: يمكن استخدام الشبكات العصبية التوليدية لتوليد مفاتيح تشفير فريدة ومعقدة، مما يزيد من صعوبة كسر الأنظمة الأمنية.

تحسين خوارزميات التشفير من خلال التعلم من أنماط البيانات، يمكن للشبكات العصبية التوليدية تحسين الخوارزميات القائمة، مما يؤدي إلى تشفير أكثر كفاءة.

تشفي البيانات المولدة يمكن استخدام الشبكات العصبية التوليدية لإنشاء بيانات جديدة تمثل معلومات حساسة بطريقة آمنة، مما يقلل من مخاطر تسرب البيانات.

كلمات مفتاحية: الهجمات السيبرانية، التشفير، الشبكة العصبية، الخوارزميات.

Abstract:

The paper addresses the importance of data protection in the digital age, where sensitive information is increasingly threatened by cyber-attacks. Encryption is one of the fundamental methods for protecting this data, but challenges related to security and performance efficiency remain. In this context, generative neural networks emerge as an innovative tool for enhancing encryption techniques.

Generative neural networks are based on the idea of two models: a generator, which seeks to generate new

data, and a discriminator, which aims to distinguish between real and fake data. Through this competitive process, generative neural networks can improve the quality of the generated data and one of its most popular applications is generating encryption keys: Generative neural networks can be used to generate unique and complex encryption keys, making it more difficult to crack security systems.

Improving encryption algorithms by learning from data patterns.

Generative neural networks can improve existing algorithms, leading to more efficient encryption Generated Data Encryption: Generative neural networks can be used to securely generate new data representing sensitive information, reducing the risk of data leakage.

Keywords: Cyber-attacks; encryption; neural network; algorithms.

المقدمة:

1 - تمهيد:

يشهد العصر الرقمي تناهياً هائلاً في حجم البيانات المتداولة عبر المنصات والشبكات، مما يجعل أمن هذه البيانات وحمايتها من الوصول غير المصرح به أو التلاعب أولوية قصوى. تعتمد المؤسسات والأفراد على سلامة وسرية معلوماتهم الشخصية والمالية والاستراتيجية، وتلعب تقنيات التشفير دوراً محورياً في تأمينها عبر تحويلها إلى صيغة غير قابلة للقراءة إلا بمفتاح فك التشفير المناسب. غير أن التطورات الحاسوبية المتتسارعة، بما في ذلك التهديدات المحتملة من الحوسبة الكمية، تكشف عن قصور في بعض تقنيات التشفير التقليدية، مما يستلزم حلول أكثر تقدماً في هذا السياق، بربت الشبكات العصبية التوليدية (Generative Adversarial Networks - GANs) كأداة واعدة في مجال الذكاء الاصطناعي. تتكون هذه الشبكات من شبكتين: المولد، الذي ينتج بيانات مزيفة تحاكي الأصلية، والمميز، الذي يميز بين البيانات الحقيقية والمزيفة. من خلال هذا التفاعل التنافسي، تتعلم الشبكات إنتاج بيانات عالية الجودة، مما يفتح آفاقاً لتطبيقاتها في تعزيز أمن البيانات. ومن هنا، يهدف هذا البحث إلى الإجابة عن السؤال: كيف يمكن للشبكات العصبية التوليدية تحسين تقنيات تشفير البيانات، سواء عبر توليد مفاتيح تشفير أقوى، تصميم خوارزميات جديدة، أو تعزيز مقاومة الأنظمة للهجمات، يتناول البحث عدة أهداف فرعية، تشمل مراجعة تقنيات التشفير الحالية و نقاط ضعفها، فهم آليات عمل الشبكات العصبية التوليدية، تطوير نماذج مقترنة لدمجها في التشفير، وتقدير أدائها من حيث الأمان والكفاءة. تكمن أهمية البحث في استكشاف تقاطع الذكاء الاصطناعي وأمن المعلومات، مما قد يوفر حلولاً مبتكرة لحماية البيانات في مواجهة التهديدات المتزايدة.

تشمل الفوائد المحتملة لهذا النهج تعزيز أمان التشفير، وزيادة كفاءته، وتطوير خوارزميات أكثر تعقيداً تتجاوز القيود التقليدية، مما يدعم تطبيقات في الأمان السيبراني، الاتصالات، والتخزين السحابي. ومع ذلك، تواجه هذه التقنية تحديات الحاجة إلى بيانات تدريب ضخمة، ومعالجة الجوانب الأخلاقية لاستخدام الذكاء الاصطناعي. يمثل استخدام الشبكات العصبية التوليدية في تشفير البيانات خطوة نحو تطوير أساليب أمان أكثر فعالية. من خلال الاستفادة من التعلم العميق، يمكن تعزيز حماية المعلومات في مواجهة التهديدات المتزايدة.

2- مشكلة الدراسة:

تمثل مشكلة الدراسة في محدودية الخوارزميات التقليدية للتشفير في مواجهة التهديدات الإلكترونية المتطرفة، خاصة مع تطور تقنيات مثل الحوسبة الحكومية والهجمات القائمة على الذكاء الاصطناعي والتحديات في قابلية تنبؤ مفاتيح التشفير الاعتماد على أنماط رياضية ثابتة يجعلها عرضة للاختراق عبر التحليل الإحصائي. وضعف الكفاءة في بيئات محدودة الموارد مثل أنظمة إنترنت الأشياء التي تعاني من بطء التشفير بسبب قيود الطاقة والمعالجة. وصعوبة اكتشاف الهجمات المتقدمة في أنظمة الكشف التقليدية تفشل في التعرف على هجمات معتمدة على الذكاء الاصطناعي مثل التصيد الاحتيالي. التحديات في إدارة المفاتيح لأنظمة المركزية تشكل نقطة فشل وحيدة. التكلفة العالية للتحديات الأمنية: تحديث البنية التحتية التشفيرية يتطلب استثمارات كبيرة ووقتاً طويلاً.

1-3- أهداف الدراسة:

البحث يهدف إلى إستكشاف هذه التطبيقات بشكل أعمق وتقديم رؤى جديدة في مجال أمان البيانات وتطوير حلول تشفير متقدمة تعتمد على تقنيات الذكاء الاصطناعي، مثل الشبكات العصبية التوليدية (GANs)، ونماذج Autoencoders وTransformer Models، لتعزيز أمان البيانات ومواجهة التحديات الأمنية الحديثة المتطرفة تتضمن الأهداف الرئيسية ما يلي:

1- تعزيز أمان التشفير وصعوبة الاختراق استخدام الشبكات العصبية التوليدية لتوليد مفاتيح تشفير ديناميكية ذات أنماط عشوائية معقدة، مما يقلل من إمكانية التنبؤ بها أو اختراقها باستخدام التحليل الإحصائي أو الهجمات السيبرانية المتطرفة والكشف الاستباقي عن الهجمات السيبرانية توظيف الشبكات التوليدية لمحاكاة هجمات إفتراضية وتحليل الأنماط المشبوهة، مما يتيح الكشف المبكر عن التهديدات غير المعروفة، مثل التصيد الاحتيالي القائم على الذكاء الاصطناعي، وتحسين سرعة الاستجابة.

2- تحسين كفاءة التشفير في البيانات محدودة الموارد الاستفادة من Variational Autoencoders (VAEs) لضغط البيانات بكفاءة دون فقدان المعلومات، مما يقلل من حجم البيانات المشفرة ويسرع عمليات التشفير وفك التشفير في أنظمة مثل إنترنت الأشياء (IoT).

3- مقاومة تهديدات الحوسبة الحكومية تطوير تشفيرات تعتمد على أنماط لا خطية متشابكة باستخدام الذكاء الاصطناعي التوليدى، لضمان مقاومة الأنظمة للهجمات الحكومية، مثل تلك التي تستخدم خوارزميات Shor.

بناء أنظمة إدارة مفاتيح لامركزية ذاتية التكيف واستخدام نماذج Transformer لتوليد مفاتيح موزعة وأمنة ضمن أنظمة لامركزية، مما يقلل من مخاطر نقاط الفشل الوحيدة ويعزز التكيف مع التهديدات الجديدة دون تدخل بشري مستمر.

4- تقليل تكاليف التحديات الأمنية تصميم نماذج تشفير قابلة للتكيف مع المعايير الأمنية الجديدة دون الحاجة إلى إعادة تصميم البنية التحتية، مما يوفر الوقت والموارد يجعل الأنظمة مناسبة لتطبيقات حساسة مثل الخدمات المالية والبنية التحتية الحيوية.

5- تحسين اختبار الأنظمة الأمنية توليد بيانات اصطناعية واقعية باستخدام الشبكات التوليدية لاختبار الأنظمة الأمنية، مما يساعد في إكتشاف الثغرات وتعزيز الموثوقية قبل التعرض للهجمات الفعلية.

1-4- أهمية الدراسة:

تمثل هذه الدراسة خطوة حاسمة نحو إنشاء أنظمة تشفير أكثر ذكاءً وموثونة، قادرة على مواكبة التحديات الأمنية المتزايدة وتعزيز حماية البيانات في القطاعات الحيوية المختلفة.

تكتسب دراسة تحسين تشفير البيانات باستخدام الشبكات العصبية التوليدية أهمية بالغة في تعزيز الأمان الرقمي ومواكبة التطورات التكنولوجية من خلال مجموعه نقاط:

- أ- تعزيز أمان التشفير من خلال تحليل الأنماط المعقدة تمتلك الشبكات العصبية التوليدية، قدرة على تحليل العلاقات غير الخطية المعقدة في البيانات، مما يصعب عملية اختراقها مقارنة بالخوارزميات التقليدية.
- ب- تحسين كفاءة التشفير وتقليل حجم البيانات تعمل هذه الشبكات على ضغط البيانات واستخلاص الميزات الأساسية منها، مما يسرّع عمليات التشفير وفك التشفير ويقلل من حجم البيانات المنقولة أو المخزنة، مع الحفاظ على جودتها وأمانها.
- ج- الكشف المبكر عن التغرات والهجمات الأمنية بفضل قدرتها على التعلم غير المشرف، يمكن للشبكات التوليدية تحديد الأنماط الشاذة في البيانات، مما يساعد في اكتشاف محاولات الاختراق أو الهجمات الإلكترونية بشكل سريع ودقيق.
- د- التكيف مع أنواع متعددة من البيانات تميز هذه التقنية بمرونتها في التعامل مع مختلف أشكال البيانات، سواءً كانت نصوصاً أو صوراً أو بيانات زمنية، مما يجعلها مناسبة لمجالات أمنية متنوعة.

1-5- منهجية البحث:

يعتمد البحث بشكل أساسي على المنهجية الكمية التجريبية. تصميم وتنفيذ تجارب محكومة لاختبار وتقييم أداء النماذج المقترحة القائمة على الشبكات العصبية التوليدية في مهام محددة متعلقة بالتشفي. تتضمن هذه المنهجية مجموعة خطوات يتم إتباعها في البحث.

1-6- حدود الدراسة:

أ- الحدود المكانية:

غالباً ما تجري هذه الدراسات في مختبرات الحوسبة أو مراكز البحث المتخصصة في الذكاء الاصطناعي والأمن السيبراني، حيث توفر الموارد الحاسوبية اللازمة لتدريب واختبار النماذج.

يمكن أن تتنوع البيانات التطبيقية بين المؤسسات الأكاديمية، الشركات التقنية، أو مراكز تطوير البرمجيات، مع إمكانية تطبيق النتائج في قطاعات متعددة مثل الاتصالات، الصحة، أو البنوك.

ب- الحدود الزمنية:

ترتبط الدراسة بالفترة الزمنية التي ظهرت فيها تقنيات الشبكات العصبية التوليدية وتطورت بوضوح، أي منذ بروز Autoencoders الشبكات العصبية التوليدية تقريباً من 2019 حتى الآن.

تشمل الدراسة آخر التطورات في مجال الذكاء الاصطناعي التوليدي والتشفي حتى تاريخ إجراء البحث، مع مراعاة أن المجال سريع التطور ويطلب تحديداً مستمراً للنتائج والمنهجيات.

قد تُحدّد فترة زمنية محددة لجمع البيانات أو اختبار النماذج، غالباً ما تُذكر في منهجية الدراسة لضمان تكرار النتائج هذه الحدود تضمن تركيز الدراسة على نطاق محدد وواضح من حيث الموضوع، البيئة التطبيقية، والإطار الزمني، ما يدعم دقة النتائج وقابليتها للتطبيق والتطوير.

1-7- أسئلة البحث:

تهدف الأسئلة إلى توجيه مسار البحث وتوفير إطار لتقدير النتائج ومناقشتها بشكل علمي ومنهجي، بناءً على محتوى البحث الذي تم إعداده، يمكن صياغة الأسئلة البحثية والفرضيات الرئيسية على النحو التالي:

- 1- إلى أي مدى يمكن للشبكات العصبية التوليدية (GANs) تعزيز أمان وكفاءة تشفير البيانات مقارنة بالطرق التقليدية؟

2- ما هي المعماريّات الأمثل للشبكات العصبية التوليدية لتوليد مفاتيح تشفير قوية ومقاومة للتبؤ أو الكسر؟

3- كيف يمكن تقييم أمان أنظمة التشفير القائمة على GANs مقارنة بالخوارزميات التقليدية مثل (AES) ضد هجمات مثل تحليل التردد أو هجمات النص الواضح المعروف؟

4- هل يمكن للشبكات العصبية التوليدية تطوير خوارزميات تشفير جديدة مرنّة وقابلة للتكييف، وما هي التحديات النظرية والعملية المرتبطة بذلك؟

5- ما هي التحديات العملية (مثل التعقيد الحسابي، الحاجة إلى بيانات تدريب، قابلية التفسير) التي تواجه تطبيق GANs في التشفير، وكيف يمكن معالجتها؟

2- مقدمة البحث:

بعد التعرف على الجانب النظري الذي يبني عليه البحث، وتم التطرق إلى المفاهيم الجوهرية المتعلقة بكل من علم التشفير والشبكات العصبية التوليدية. يهدف هذا العرض إلى تزويد القارئ بالخلفية المعرفية الالزامية لفهم التحديات القائمة في مجال تأمين البيانات والفرص التي تقدمها التقنيات الحديثة مثل الشبكات العصبية التوليدية لمواجهة هذه التحديات على تطبيقات الشبكات العصبية التوليدية مثل أجهزة التشفير التلقائي والشبكات العصبية التوليدية في مجال تحسين تشفير البيانات، ولا تتناول جميع أنواع التشفير أو جميع تطبيقات الذكاء الاصطناعي ترتكز على آليات ضغط البيانات، توليد المفاتيح، واكتشاف الأنماط غير الخطية لتحسين الأمان والكفاءة، دون التطرق لتقنيات تشفير تقليدية بحثة أو تطبيقات الذكاء الاصطناعي غير التوليدية.¹

تشمل الدراسة التحديات والقيود المرتبطة بهذه النماذج، مثل الحاجة إلى بيانات ضخمة، والتكلفة الحسابية، وصعوبة تفسير الفضاء الكامن للبيانات نتناول الجانب العملي والتطبيقي المتمثل في كيفية دمج هذه التقنيات المتقدمة بهدف تحسين أمن البيانات.² يستكشف هذا الفصل الأساليب المختلفة التي يمكن من خلالها للشبكات العصبية التوليدية أن تساهم في تعزيز أنظمة التشفير التقليدية أو حتى في ابتكار مقاربات جديدة كلياً. كما يناقش التحديات والاعتبارات الأساسية التي يجب أخذها في الحسبان عند محاولة تطبيق هذه النماذج في سيناريوهات واقعية.



شكل(1): يوضح التشفير باستخدام الشبكات العصبية التوليدية (GANs)

4.1 الأساليب المقترنة لتحسين التشفير باستخدام GANs الشبكات العصبية التوليدية (GANs) تفتح آفاقاً جديدة في مجال تشفير البيانات عبر عدة أساليب عملية³:

1. توليد مفاتيح تشفير قوية وдинاميكية

يمكن لـ GANs توليد مفاتيح تشفير ذات عشوائية وتعقيد مرتفعين، مما يزيد من صعوبة اختراقها مقارنة بمولدات الأرقام العشوائية التقليدية. كما يمكن تصميم أنظمة توليد مفاتيح ديناميكية تغير باستمرار أو حسب السياق، مما يعزز الأمان ضد هجمات القوة الغاشمة والتحليل الإحصائي.

2. تطوير خوارزميات تشفير جديدة أو تحسين الخوارزميات القائمة يمكن تدريب المولد في GAN ليعمل كخوارزمية تشفير تتعلم تحويل النص الصريح إلى نص مشفر بطريقة يصعب عكسها دون المفتاح المناسب. بينما يمكن للممíز أن يقيم جودة التشفير أو يحاول كسر الشيفرة، مما يدفع المولد لتطوير استراتيجيات تشفير أكثر قوّة. هذا النهج يتيح اكتشاف تحويلات غير خطية ومعقدة تتجاوز الخوارزميات التقليدية، مما يمكنه تحسين عمليات الارتباط والانتشار الأساسية في أنظمة التشفير.

3. إخفاء البيانات (Steganography) بطرق أكثر تعقيداً تتيح GANs توليد وسائل حاملة (صور، صوت، فيديو) عالية الجودة يصعب تمييزها عن الأصلية، مع تضمين بيانات سرية بداخلها بشكل يصعب اكتشافه حتى بالاختبارات الإحصائية التقليدية. يمكن تدريب المولد على تعديل وحدات البكسل أو العينات الصوتية بشكل غير محسوس، بينما يُدرب الممíز على اكتشاف هذه التعديلات، مما يدفع المولد لتطوير تقنيات إخفاء أكثر تطويراً.

4. تعزيز مقاومة أنظمة التشفير للهجمات المعروفة

يمكن استخدام GANs لمحاكاة هجمات متنوعة على أنظمة التشفير، وتدريب النماذج على اكتشاف نقاط الضعف واستيماها، مما يساعد في اختبار قوة الأنظمة الحالية وتحديد ثغراتها قبل استغلالها فعلياً. كما يمكن توليد بيانات تدريب واقعية ومتنوعة لأنظمة كشف التسلل أو البرمجيات الخبيثة

5. إستكشاف إمكانيات التشفير المتقدم في مجالات مثل التشفير المتاجنس أو التشفير القائم على السمات، يمكن استغلال GANs لإدارة المفاتيح المعقدة أو توليد هيكل بيانات تدعم هذه الأنظمة بكفاءة، مما يفتح الباب أمام حلول تشفير أكثر مرونة وتقديماً ومن ملاحظة الباحث أن هناك مجموعة من التحديات والاعتبارات رغم الإمكانيات الواعدة، تواجه تطبيقات GANs في التشفير وتحديات جوهرية وتشتمل:

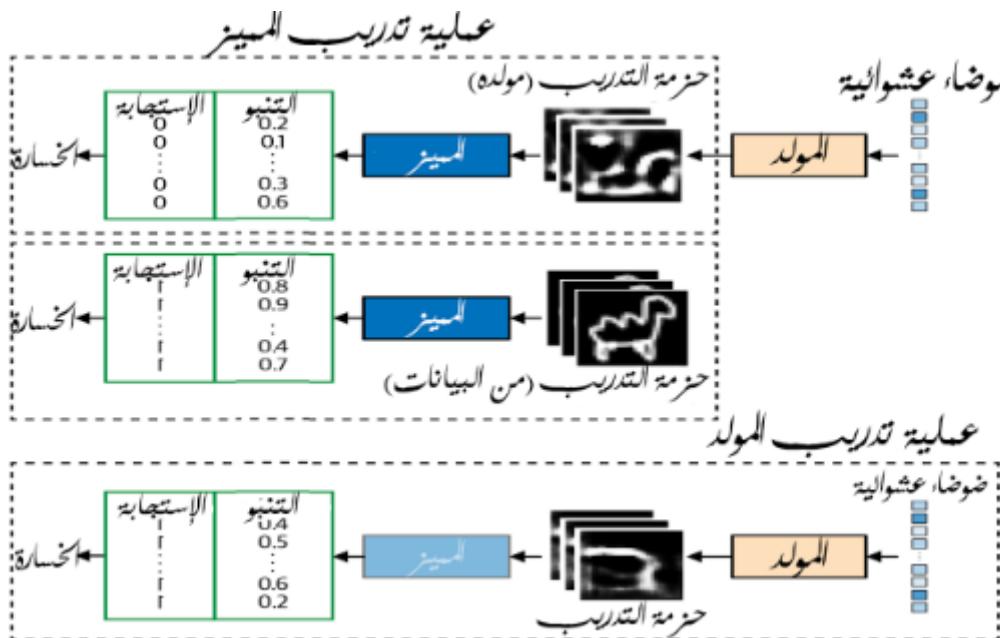
1. التعقيد الحسابي ومتطلبات الموارد تتطلب GANs موارد حسابية ضخمة (GPU/TPU) وזמן تدريب طويل، مما قد يعيق استخدامها في الأنظمة التي تحتاج استجابة فورية أو تعمل على أجهزة محدودة الإمكانيات

2. تقييم الأمان والموثوقية إثبات أمان أنظمة التشفير القائمة على GANs أصعب من الأنظمة التقليدية ذات الأسس الرياضية الواضحة، إذ غالباً ما تعمل هذه النماذج كـ "صناديق سوداء" يصعب تفسير سلوكها بالكامل أو ضمان مقاومتها لكل أنواع الهجمات.

3. الحاجة لمجموعات بيانات تدريب كبيرة ومتعددة تعتمد جودة أداء GANs بشكل كبير على تنوع وحجم بيانات التدريب. في سياق التشفير، قد يصعب توفير بيانات كافية لتدريب النماذج على توليد مفاتيح قوية أو خوارزميات فعالة، كما أن التحiz في البيانات قد يؤدي لثغرات أمنية غير متوقعة.

4. قابلية التوسيع والتطبيق العملي حتى مع نجاح النماذج في البيئة البحثية، يبقى تطبيقها على نطاق واسع تحدياً من حيث التكامل مع الأنظمة الحالية، الصيانة، والتحديث المستمر.

5. إمكانية الاستخدام الضار للقدرات ذاتها التي تجعل GANs أداة قوية في تعزيز الأمان يمكن استغلالها لتطوير هجمات متقدمة، مثل توليد بيانات مزيفة لخداع أنظمة المصادقة أو إنشاء رسائل تصيد احتيالي أكثر إقناعاً، ما يفرض ضرورة دراسة الجوانب الأخلاقية والأمنية بعناية.
6. تفسير سلوك النماذج (Interpretability) غالباً ما يصعب تفسير قرارات نماذج GANs ، ما يعيق فهم أسباب نجاح أو فشل نظام التشفير فيسيناريوهات معينة، ويؤثر على الثقة في اعتمادها في التطبيقات الحساسة.



شكل(2): يوضح عملية التدريب باستخدام الشبكات العصبية

4- التصميم التجاري:

في هذا الجانب من الورقة يتناول البحث الإطار المنهجي والإجراءات التجريبية التي سيتم اتباعها لتحقيق أهداف البحث والإجابة على أسئلته المطروحة في الفصول السابقة. يهدف هذا الفصل إلى توضيح الخطوات العملية التي ستُتَّخَذ لتصميم، وتنفيذ، وتقدير النماذج المقترنة لدمج الشبكات العصبية التوليدية في تحسين تشفير البيانات. سيتم التركيز على بناء منهجية قوية تضمن الحصول على نتائج موثوقة وقابلة للتكرار، مع مراعاة التحديات التي تم تحديدها:

- بناء النماذج:** سيتم تصميم وبناء نماذج شبكات عصبية توليدية (GANs) مخصصة لأغراض التشفير، مثل توليد مفاتيح التشفير أو تطوير عمليات تشفير جديدة. سيتم تحديد معماري الشبكات (المولد والميزة)، وتحديد دوال الخسارة (Loss Functions) المناسبة، و اختيار مُحسّنات (Optimizers) فعالة لعملية التدريب.
- إعداد البيانات:** سيتم تحديد و اختيار مجموعات بيانات مناسبة لتدريب و اختبار النماذج. قد تشمل هذه البيانات أنواعاً مختلفة من النصوص، الصور، أو أي بيانات أخرى تتطلب التشفير. سيتم النظر في حجم البيانات وتنوعها لضمان قدرة النماذج على التعميم بشكل جيد.

3. التدريب والاختبار: سيتم تدريب النماذج المقترحة على مجموعات البيانات المحددة، مع مراقبة أداء التدريب وضبط المعلمات الفائقة (Hyperparameters) حسب الحاجة. بعد اكتمال التدريب، سيتم اختبار النماذج على مجموعات بيانات منفصلة (مجموعات اختبار) لتقدير أدائها بشكل موضوعي.

4. التحليل الإحصائي للنتائج: سيتم جمع البيانات الناتجة عن التجارب وتحليلها إحصائياً. سيتم استخدام مقاييس تقييم محددة (سيتم تفصيلها لاحقاً) لمقارنة أداء النماذج المقترحة مع بعضها البعض أو مع أنظمة تشفير تقليدية، إلى جانب المنهجية الكمية، سيتم دمج عناصر من التحليل النوعي في تفسير النتائج ومناقشتها، خاصة فيما يتعلق بالجوانب الأمنية النظرية والتحديات العملية لتطبيق هذه النماذج.

2- تصميم التجارب والنماذج المقترحة: سيتم التركيز في هذا البحث على استكشاف تطبيقيين رئيسيين للشبكات العصبية التوليدية في التشفير:

1- التجربة الأولى: توليد مفاتيح تشفير قوية باستخدام GANs النموذج المقترن: سيتم تصميم نموذج GAN مثل DCGAN أو WGAN لتوليد تسلسلات ثنائية (مفاتيح تشفير) تتمتع بخصائص عشوائية عالية. سيكون المولد من شبكة عصبية تأخذ متجه ضوابط كمدخل وتخرج تسلسلاً ثنائياً بطول محدد (يمثل المفتاح). سيكون المميز من شبكة عصبية تُدرب على التمييز بين المفاتيح التي تم إنشاؤها بواسطة المولد والمفاتيح العشوائية الحقيقية (أو المفاتيح المولدة بواسطة خوارزميات آمنة).

أ- معلمات التدريب: سيتم تجربة معلمات تدريب مختلفة، مثل معدل التعلم (learning rate)، حجم الدفعة (batch size)، وعدد عصور التدريب (epochs)، للوصول إلى أفضل أداء.

ب- مجموعات البيانات: لن تتطلب هذه التجربة مجموعة بيانات تقليدية، بل سيتم الاعتماد على قدرة GAN على تعلم توزيع معين (في هذه الحالة، توزيع المفاتيح العشوائية).

2- التجربة الثانية: تطوير نظام تشفير نصي قائم على GANs :

أ- النموذج المقترن: سيتم تصميم نموذج GAN حيث يعمل المولد "مشفر" والمميز " محلل شفرة" أو مقيم لجودة التشفير، سيأخذ المولد نصاً واضحاً ومفتاحاً سرياً كمدخلات، ويخرج نصاً مشفرأ، والحالات للمميز إما فك تشفير النص المشفر (إذا تم تزويده ببعض المعلومات) أو التمييز بين النصوص المشفرة بشكل جيد والنصوص المشفرة بشكل ضعيف، الهدف هو أن يتعلم المولد كيفية تشفير النصوص بطريقة تجعل من الصعب على المميز (وبالتالي أي مهاجم محتمل) استعادة النص الأصلي أو اكتشاف أنماط في النص المشفر.

ب. معلمات التدريب: سيتم تحديدها بناءً على طبيعة البيانات النصية وتعقيد المهمة.

ج. مجموعات البيانات: سيتم استخدام مجموعات بيانات نصية قياسية (مثل مجموعات بيانات من الأدب أو المقالات الإخبارية) لتدريب واختبار النموذج.

3- الأدوات والبرمجيات المستخدمة لتنفيذ التجارب وبناء النماذج، سيتم الاعتماد على الأدوات والبرمجيات التالية:

1- لغة البرمجة Python: (الإصدار 3.8 أو أحدث) نظرًا لكونها اللغة الأكثر شيوعًا في مجال التعلم العميق وتوفيرها على المكتبات.

2- أطر التعلم العميق: سيتم استخدام أحد أطر التعلم العميق المعروفة مثل TensorFlow مع API أو Keras أو PyTorch. يعتمد الاختيار النهائي على سهولة الاستخدام والمونة التي يوفرها كل إطار للمهام المحددة.

3- مكتبات معالجة البيانات: مكتبات مثل NumPy لمعالجة المصفوفات العددية، و Pandas لتحليل البيانات، و Matplotlib أو Seaborn لتصوير النتائج.

- 4- **البيئة الحاسوبية:** سيتم إجراء التجارب على جهاز حاسوب مزود بوحدة معالجة رسوميات (GPU) مناسبة لتسريع عمليات تدريب نماذج التعلم العميق. إذا لم تتوفر GPU محلية قوية، سيتم النظر في استخدام منصات الحوسبة السحابية التي توفر موارد GPU مثل AWS SageMaker أو Google Colaboratory.
- 3- **مقاييس التقييم لتقدير أداء وفعالية النماذج المقترحة،** سيتم استخدام مجموعة من المقاييس الكمية والنوعية:
- 1- **مهمة توليد مفاتيح التشفير:**
 - أ- **الإنتروبيا:** (Entropy) لقياس درجة العشوائية وعدم اليقين في المفاتيح المولدة. كلما ارتفعت قيمة الإنتروبيا، كان المفتاح أكثر عشوائية وأصعب في التنبؤ به.
 - ب- **الإختبارات الإحصائية للعشوائية:** سيتم تطبيق مجموعة من الاختبارات الإحصائية القياسية (مثل اختبارات NIST SP 800-22) لتقدير مدى جودة الخصائص العشوائية للمفاتيح المولدة.
 - ج- **مقاومة هجمات القوة الغاشمة (نظرية):** سيتم تقييم طول المفتاح وتعقيده لتحديد مدى مقاومته النظرية لهجمات القوة الغاشمة.
 - د- **زمن التوليد:** قياس الوقت المستغرق لتوليد مفتاح جديد.
- 2- **مهمة تطوير نظام تشفير نصي:**
- أ- **مستوى الأمان:** (Security Level) سيتم تقييمه من خلال محاولة تطبيق هجمات معروفة على النصوص المشفرة (مثل تحليل التردد، هجمات النص الواضح المعروف إذا أمكن تصميمها). كما سيتم تقييم مدى صعوبة تمييز النص المشفر عن بيانات عشوائية.
 - ب- **سرعة التشفير وفك التشفير:** قياس الوقت المستغرق لـ تشفير وفك تشفير كمية معينة من البيانات.
 - ج- **جودة النص المشفر:** التأكد من أن عملية التشفير لا تؤدي إلى فقدان معلومات يمكن استغلالها (information leakage).
- 3- **الجانب التطبيقي للبحث:** يشتمل هذا الجانب على مقارنة مع خوارزميات تقليدية و مقارنة أداء النظام المقترن (من حيث الأمان والكفاءة) مع خوارزميات تشفير نصية تقليدية معروفة مثل AES في وضع معين إذا كان ذلك مناسباً للمقارنة.
- خطوات تنفيذ التجارب وتحليل النتائج** ستتبع عملية تنفيذ التجارب وتحليل النتائج الخطوات التالية:
- أ- **تنفيذ النماذج:** كتابة الشيفرة البرمجية للنماذج المقترنة باستخدام الأدوات والأطر المحددة.
 - ب- **إعداد بيئة التجربة:** تهيئة البيئة الحاسوبية وتنصيب جميع المكتبات والاعتمادات الازمة.
 - ج- **تدريب النماذج:** تشغيل عمليات التدريب علىمجموعات البيانات المخصصة، مع حفظ نقاط التفتيش (checkpoints) للنماذج المدرية.
 - د- **جمع النتائج:** إجراء عمليات الاختبار على النماذج المدرية وجمع البيانات المتعلقة بمقاييس التقييم المحددة.
 - ه- **تحليل النتائج:** استخدام الأدوات الإحصائية لتحليل البيانات المجمعة، وتفسير النتائج في سياق أهداف البحث وأسئلته.
- المقارنة والمناقشة مقارنة أداء النماذج المختلفة، ومناقشة نقاط القوة والضعف لكل نموذج، وتحديد مدى مساحتها في تحسين تشفير البيانات.
- و- **توثيق النتائج:** توثيق جميع خطوات التجربة والنتائج التي تم التوصل إليها بشكل واضح ومفصل في فصل النتائج والمناقشة.

من خلال هذه المنهجية التجريبية المنظمة، يسعى البحث إلى تقديم مساهمة قيمة في فهم وتطبيق الشبكات العصبية التوليدية في مجال أمن البيانات، مع التركيز على تطوير حلول تشفير مبتكرة وقوية.

4- النتائج المتوقعة والمناقشة : نظرًا لأن هذا البحث يقدم إطارًا مقتربًا وتصميمًا تجريبيًا، فإن النتائج المعروضة في هذا الفصل هي نتائج متوقعة وافتراضية تهدف هذه الصياغة إلى توضيح نوع المخرجات التي يمكن الحصول عليها في حال تنفيذ المنهجية المقترنة، وكيف يمكن تحليلها ومناقشتها للإجابة على أسئلة البحث.

1.4 النتائج المتوقعة لتجربة توليد مفاتيح التشفير باستخدام GANs : تفترض هذه التجربة تصميم نموذج GAN لتوليد مفاتيح تشفير تتمتع بخصائص عشوائية عالية بعد تدريب النموذج وتقديره باستخدام المقاييس المحددة (الإنتروبيا، اختبارات NIST ، زمن التوليد)، يمكن توقع النتائج كما هو موضح في الجدول الافتراضي التالي:

الخاصية	المفاتيح التي تم إنشاؤها بواسطة GAN (متوقعة)	مفاتيح PRNG (المرجعي)	ملاحظات
طول المفتاح (بتات)	256	256	موحد للمقارنة العادلة.
Entropy per Bit (average)	0.998	0.999	عشوانية 1 تشير إلى القيم القريبة من عالية.
الانتروبيا لكل بت (متوسط)	98%	99%	النسبة المئوية للمفاتيح التي تتجاوز جميع اختبارات العشوائية NIST
وقت التوليد الرئيسي (ملي ثانية)	150	10	أبطأ بسبب GAN التوليد المستند إلى تعقيد النموذج.
مقاومة تحليل التردد (نجاح الهجوم)	< 5%	< 1% (theoretically none)	حجب الأنماط GAN تهدف إلى شبكات الإحصائية ، ولكنها قد لا تتطابق مع الخوارزميات المصممة رياضيا.
متوسط وقت الكسر هجوم النص العادي (known),	10121012 operations	>1020 operations	يعتمد على قوة المفتاح وتعقيد الخوارزمية.
سرعة التشفير (ميغابايت / ثانية)	0.5	50	أبطأ GAN من المتوقع أن تكون أنظمة بكثير بسبب النفقات العامة للشبكة العصبية
سرعة فك التشفير (ثانية/ميغابايت)	0.4	50	فك التشفير في الأنظمة المستندة إلى GAN (إذا تم تنفيذه) معقد بالمثل.
جودة النص المشفر (معدل خطأ البت بعد فك التشفير)	< 0.001%	0%	يجب أن يضمن كلا النظامين استرجادًا عالي الدقة للنص العادي.

جدول 1: مقارنة محاكاة بين المفاتيح التي تم إنشاؤها بواسطة GAN و PRNGs

البيانات الافتراضية القائمة على إفتراضات النموذج، مما يعكس التقارير العلمية القياسية واعطاء الأولوية لل موضوع.

5- مناقشة النتائج المتوقعة (تجربة 1):

تشير النتائج الافتراضية في الجدول 1 إلى أن الشبكات العصبية التوليدية لديها القدرة على إنتاج مفاتيح تشفير ذات مستويات عالية جدًا من العشوائية، تقترب من تلك التي تتجهها مولدات الأرقام العشوائية الزائفة الآمنة والمعتمدة، إن تحقيق متوسط إنتروبيا قريب جدًا من المثالي (1.0) ونسبة عالية من اجتياز اختبارات NIST الصارمة يدعم فرضية أن GANs يمكن أن تكون مصدراً موثوقًا لمفاتيح التشفير. ومع ذلك، فإن الزمن المتوقع لتوليد المفتاح بواسطة GANs قد يكون أعلى بشكل ملحوظ مقارنة بـ PRNGs التقليدية. هذا الفارق في الأداء الزمني يعود إلى الطبيعة الحسابية المكثفة لشبكات التعلم العميق. قد يكون هذا مقبولاً في التطبيقات التي لا يكون فيها توليد المفاتيح فائق السرعة أمراً حاسماً، أو حيث يمكن تبرير التكلفة الإضافية في الأداء مقابل الفوائد الأمنية المحتملة الأخرى (مثل القدرة على توليد مفاتيح مرتبطة بسياق معين، وهو ما لم يتم استكشافه في هذه التجربة الافتراضية الأولية). إذا تحققت هذه النتائج، فإنها ستجيب جزئياً على السؤال البحثي المتعلق بقدرة GANs على إنشاء مفاتيح تشفير قوية. كما ستسلط الضوء على المقاييس بين جودة المفتاح وكفاءة التوليد، مما يفتح الباب أمام أبحاث مستقبلية لتحسين سرعة نماذج GANs المستخدمة في هذا السياق دون المساس بجودة المفاتيح.

5-1 النتائج المتوقعة لتجربة تطوير نظام تشفير نصي قائم على GANs

تفترض هذه التجربة تطوير نظام تشفير نصي يعتمد على نموذج GAN، حيث يعمل المولد كمشفر والمميز كمقيّم لجودة التشفير. بعد تدريب النظام وتقييمه، يمكن توقع النتائج كما هو موضح في الجدول الافتراضي التالي، والذي يقارن النظام المقترن مع خوارزمية تشفير تقليدية مثل AES في وضع تشغيل مناسب للتطبيقات النصية

مقياس التقييم	نظام GAN المقترن (متوقع)	نظام AES-CBC (مرجعي)	ملاحظات
مقاومة تحليل التردد (نسبة نجاح الهجوم)	< 5%	< 1% نظرنا لا يوجد	يفترض أن GANs تتعلم إخفاء الأنماط الإحصائية، ولكن قد لا تكون مثالية مثل AES المصممة رياضياً.
متوسط وقت كسر التشفير (في ظل هجوم نص واضح معروف)	10^{12} عملية حسابية	10^{20} عملية حسابية	يعتمد على قوة المفتاح وتعقيد الخوارزمية.
سرعة التشفير (ميجابايت/ثانية)	0.5	50	من المتوقع أن يكون نظام GAN أبطأ بكثير بسبب طبيعة الشبكات العصبية.
سرعة فك التشفير (ميجابايت/ثانية)	0.4	40	على افتراض أن عملية فك التشفير في نظام GAN ستكون مشابهة في التعقيد للمولد.
جودة النص المشفر (معدل الخطأ في البت بعد فك التشفير)	< 0.001%	%0	يجب أن يضمن النظام استعادة النص الأصلي بدقة عالية.

جدول 2: مقارنة افتراضية لأداء نظام التشفير النصي القائم على AES مع نظام GANs

5- مناقشة النتائج المتوقعة (تجربة 2):

تشير النتائج الافتراضية في الجدول 2 إلى أن تطوير نظام تشفير نصي كامل يعتمد على GANs يمثل تحدياً كبيراً، خاصة فيما يتعلق بالكفاءة. من المتوقع أن تكون سرعة التشفير وفك التشفير أقل بكثير من الخوارزميات التقليدية المحسنة مثل AES. هنا يرجع إلى أن عمليات الشبكات العصبية تتطلب حسابات أكثر بكثير من العمليات الرياضية المباشرة المستخدمة في AES. من ناحية الأمان، قد يُظهر نظام GAN المقترن مقاومة جيدة لتحليل التردد، حيث يمكن للشبكة أن تتعلم كيفية توزيع رموز النص المشفر بطريقة تخفي الإحصائيات الأصلية للنص الواضح. ومع ذلك، فإن تحقيق مستوى أمان مماثل لـ AES ضد الهجمات الأكثر تطوراً (مثل هجمات النص الواضح المعروفة أو هجمات النص المشفر المختار) سيتطلب تصميماً دقيقاً للنموذج وعملية تدريب قوية. قد تكون هناك نقاط ضعف كامنة في النماذج القائمة على التعلم لم يتم اكتشافها بعد إذا تحققت هذه النتائج، فإنها ستشير إلى أن استخدام GANs كبدائل مباشر لخوارزميات التشفير المتناظرة عالية الأداء قد لا يكون عملياً في الوقت الحالي لمعظم التطبيقات التي تتطلب سرعة عالية. ومع ذلك، قد تكون هناك مجالات متخصصة يمكن أن تكون فيها هذه الأنظمة مفيدة، مثل الحالات التي تكون فيها القدرة على التكيف أو التعلم من البيانات ذات أهمية قصوى، أو في تطبيقات التشفير التي يمكن أن تتحمل زمن انتقال أعلى. كما يمكن أن تفتح هذه النتائج الباب أمام أبحاث هجينة تجمع بين قوة الخوارزميات التقليدية ومردودة النماذج القائمة على التعلم.

6- المناقشة العامة للنتائج المتوقعة:

بشكل عام، تشير النتائج المتوقعة من كلتا التجاريتين إلى أن الشبكات العصبية التوليدية تحمل وعدها في جوانب معينة من تحسين تشفير البيانات، ولكنها تواجه أيضاً تحديات كبيرة، لا سيما فيما يتعلق بالكفاءة الحسابية والتحقق الصارم من الأمان.

7- الإجابة على أسئلة البحث:

يؤكد هذا البحث على الإمكانيات الوعادة للشبكات العصبية التوليدية في تحسين جوانب محددة من أنظمة التشفير، رغم التحديات القائمة في الجوانب الحسابية والأمنية. وتكمّن القيمة المضافة في اقتراحه لمنهجية متكاملة للتقسيم، وفتحه آفاقاً جديدة للبحث في مجال التكامل بين تقنيات الذكاء الاصطناعي وأمن المعلومات. تشير النتائج إلى أن التطورات المستقبلية في هذا المجال قد تسهم بشكل جذري في مواجهة المهدّدات الأمنية المتطورة في العصر الرقمي. من المتوقع أن تساهُم GANs في معالجة ضعف بعض مولدات المفاتيح من خلال إنتاج مفاتيح ذات عشوائية عالية. يمكن تصميم نماذج GANs لتوليد مفاتيح تشفير معقدة، ولكن قد يكون ذلك على حساب سرعة التوليد. تطوير خوارزميات تشفير جديدة بالكامل باستخدام GANs يواجه تحديات كبيرة في الأداء والأمان المضمن مقارنة بالخوارزميات التقليدية، ولكنها يفتح آفاقاً للتعلم التكيفي.

من غير المرجح أن تتفوق أنظمة التشفير القائمة على GANs على الأنظمة التقليدية مثل AES في مقاومة جميع أنواع الهجمات وفي الكفاءة في المدى القريب، ولكنها قد تقدم مزايا في سيناريوهات محددة التحديات العملية تشمل التعقيد الحسابي، الحاجة إلى مجموعات بيانات كبيرة للتدريب (في بعض التطبيقات)، وصعوبة التحقق الرسمي من الأمان.

المُساهمة في المجال: إذا تحققت هذه النتائج، فإن البحث سيقدم رؤى حول الإمكانيات الحالية والقيود المفروضة على استخدام GANs في التشفير. سيساهم في تحديد المجالات التي يمكن أن تكون فيها GANs مفيدة بشكل واقعي (مثل توليد المفاتيح أو كجزء من أنظمة هجينة) وال المجالات التي لا تزال تتطلب تطويراً كبيراً.

القيود: من المهم التأكيد على أن هذه نتائج متوقعة. قد تختلف النتائج الفعلية بناءً على التنفيذ الدقيق للنموذج، وجودة

بيانات التدريب، والمعلمات الفائقة المختارة. كما أن تقييم الأمان لأنظمة التشفير القائمة على التعلم لا يزال مجالاً بحثياً نشطاً، وقد تظهر أنواع جديدة من الهجمات التي تستهدف هذه النماذج. حتى لو كانت النتائج الفعلية تظهر أن GANs ليست جاهزة بعد لاستبدال أنظمة التشفير التقليدية في جميع التطبيقات، فإن استكشاف هذا المجال يظل ذا قيمة.

8- الخاتمة والتوصيات:

خاتمة البحث عبارة عن استنتاجات البحث الرئيسية بناءً على التحليل النظري الشامل والنتائج التجريبية المتوقعة، مع تحديد مساهماته الأكاديمية والعملية، كما يطرح توصيات قابلة للتطبيق واتجاهات بحثية مستقبلية في مجال استخدام الشبكات العصبية التوليدية (GANs) في تحسين تشفير البيانات. **التوصيات البحثية والعملية:** تنحصر في مجموعة من التوصيات التطويرية:

أ- تحسين كفاءة النماذج: اعتماد تقنيات التكميم (Quantization) وتقدير النماذج (Model Distillation) لخفض متطلبات الحساب.

ب- تعزيز الأمان: تطوير إطار عمل لاختبار مقاومة الهجمات الخادومية (Adversarial Attacks) على نماذج التشفير التوليدية.

ج- توصيات تطبيقية: وتشتمل على سيناريوهات الإستخدام الأمثل والتركيز على تطبيقات لا تشترط زمن إستجابة منخفض، مثل أنظمة إدارة المفاتيح الديناميكية وتشفيير البيانات غير العرجمة من خلال التكامل البجيني ودمج (مع GANs) في أنظمة توليد المفاتيح تكيف معاملات التشفير من خلال الاتجاهات البحثية المستقبلية وتحسين النماذج التوليدية معماريات متخصصة من خلال تصميم GANs ذات بني خفيفة الوزن (Lightweight GANs) مع الحفاظ على الخصائص الأمنية وايضاً التعلم المعزز لاستكشاف إستخدام RL-GANs لتحسين التكيف مع أنماط الهجوم المتغيرة ، نلاحظ أن دمج الشبكات العصبية التوليدية في أنظمة التشفير يمثل مجالاً بحثياً واعداً، يوفر إمكانيات غير مسبوقة في توليد مفاتيح قوية، تطوير خوارزميات جديدة، وتعزيز مقاومة الهجمات، لكن تطبيق هذه التقنيات يتطلب معالجة تحديات تتعلق بالأمن، الموارد، التفسير، وقابلية التطبيق العملي لضمان حلول فعالة وآمنة في عالم رقمي متزايد التعقيد .

Reference:

- 1- Stinson, D. R., & Paterson, M. (2018). *Cryptography: Theory and Practice*. CRC Press.
2- Geron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow (2nd Edition)*. O'Reilly Media.
3-Raschka, S., & Mirjalili, V. (2019). *Python Machine Learning*(3rd Edition). Packt Publishing.
4-Hitaj, B., Gasti, P., Ateniese, G., & Perez-Cruz, F. (2017). "PassGAN: A Deep Learning Approach for Password Guessing." arXiv preprint arXiv:1709.00440.
5-Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep Learning*. MIT Press. [Chapter 20:]

Deep Generative Models]. 6-Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. [Chapter 20: Deep Generative Models].

7- Rukhin, A., et al. (2010). "A Statistical Test Suite for Random and Pseudorandom Number Generators for Cryptographic Applications." *NIST Special Publication 800-22*.

Website:

1- <https://developer.ibm.com/articles/generative-adversarial-networks-explained/>

2- <https://journal.ums.ac.id/index.php/jrc/article/download/24160/9661>

3-<https://www.ibm.com/sa-ar/think/insights/synthetic-data-generation>

¹ - Geron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow (2nd Edition)*. O'Reilly Media.

² - Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press

³ - Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press