



كشف هجمات حجب الخدمة الموزعة (DDoS) باستخدام نماذج التعلم العميق

الهام يخلف أبو الشواشي

قسم التقنية الالكترونية - كلية التقنية الهندسية زوارة - ليبيا

Detecting Distributed Denial-of-Service (DDoS) Attacks Using Deep Learning Models

Imam Khalaf Abushawashi

Department of Electronic Technology - Faculty of Engineering Technology,
Zuwarah – Libya

elham_abuelshwashi@yahoo.com

تاريخ الاستلام: 2026/02/11 - تاريخ المراجعة: 2026/03/12 - تاريخ القبول: 2026/03/13 - تاريخ النشر: 2026/04/22

المخلص

تعد هجمات حجب الخدمة الموزعة (Distributed Denial of Service – DDoS) من أخطر التهديدات الأمنية التي تواجه الشبكات الحاسوبية في الوقت الحالي، لما تسببه من تعطيل للخدمات وخسائر تقنية واقتصادية جسيمة. واستنزاف لموارد الشبكة. هناك عدة طرق مستخدمة للكشف عن هذه الهجمات تعتمد هذه الطرق على التوافق أو القواعد الثابتة أو أساليب إحصائية محدودة، مما يقلل من قدرتها على اكتشاف الهجمات الحديثة والمعقدة ذات الأنماط المتغيرة. يهدف هذا البحث إلى تقديم نهج ذكي لكشف هجمات DDoS بالاعتماد على نماذج التعلم العميق، من خلال تحليل خصائص حركة مرور الشبكة واستخلاص الأنماط الخبيثة بدقة عالية. تم استخدام نموذج الشبكة العصبية العميقة DNN ونموذج الشبكة العصبية المتكررة من نوع الذاكرة طويلة وقصيرة المدى LSTM كما تم استخدام مجموعة بيانات معيارية معتمدة في مجال أمن الشبكات، مع تطبيق عدد من خطوات المعالجة المسبقة، شملت تنظيف البيانات وتطبيعها واختيار الخصائص الأكثر تأثيراً. ثم جرى تدريب وتقييم النموذجين، ومقارنتهما باستخدام مقاييس تقييم معيارية مثل الدقة، والاستدعاء، ومعدل الإنذارات الخاطئة.

أظهرت النتائج تفوق نموذج LSTM في كشف هجمات DDoS مقارنة بنموذج DNN، حيث حقق دقة أعلى وانخفاضاً في معدلات الإنذارات الخاطئة. تؤكد هذه النتائج فاعلية استخدام التعلم العميق في تعزيز أنظمة كشف التسلل، وتبرز أهميته في دعم أمن الشبكات الحاسوبية ومواجهة التهديدات السيبرانية المتطورة.

الكلمات المفتاحية

أمن المعلومات، هجمات حجب الخدمة، هجمات حجب الخدمة الموزعة، كشف التسلل، التعلم العميق، أمن الشبكات، الشبكات العصبية، DNN، LSTM

1. المقدمة

شهدت الشبكات الحاسوبية تطوراً متسارعاً في السنوات الأخيرة، مما أدى إلى زيادة الاعتماد على الخدمات الرقمية في مختلف المجالات. ومع هذا التطور، برزت تهديدات أمنية متقدمة، وأصبحت الهجمات السيبرانية، وبالأخص هجمات حجب الخدمة الموزعة (DDoS) من أخطر التهديدات الأمنية التي تؤثر على توفر الخدمات واستقرار الأنظمة. تمثل هذه الهجمات تهديداً خطيراً لاستمرارية الأعمال والخدمات الرقمية.

تعتمد الأساليب التقليدية في الكشف عن هذه الهجمات على قواعد ثابتة أو توقع معروفة، ومع تطور هذه الهجمات وتغيير أنماطها أصبحت الطرق التقليدية المستخدمة للكشف عن هذه الهجمات غير مجدية حيث تعتمد أنظمة الكشف التقليدية على قواعد ثابتة أو طرق إحصائية، مما يجعلها غير قادرة على اكتشاف الهجمات الحديثة والمعقدة.

ومع التطور في تقنيات الذكاء الاصطناعي برز التعلم الآلي كحل فعال لبناء أنظمة قادرة على الكشف الاستباقي لمثل هذه الهجمات عبر التعرف على الأنماط غير الطبيعية في حركة المرور.

2. مشكلة البحث

تعاني أنظمة كشف التسلل التقليدية من:

- ضعف القدرة على اكتشاف هجمات DDoS المتطورة
- ارتفاع نسبة الإنذارات الخاطئة (False Positives)
- عدم التكيف مع أنماط الهجوم الجديدة

3. أهداف البحث

يهدف هذا البحث إلى:

1. تصميم نموذج تعلم عميق لاكتشاف هجمات DDoS.
2. تقليل معدل الإنذارات الخاطئة.
3. تحسين دقة الكشف في الزمن الحقيقي.
4. تقييم النموذج باستخدام بيانات حقيقية أو شبه حقيقية.

4. مفهوم هجمات حجب الخدمة

هجوم حجب الخدمة (DoS) هو نوع من الهجمات السيبرانية يهدف إلى تعطيل أو إيقاف خدمة إلكترونية عن العمل من خلال استهلاك موارد النظام المستهدف، مثل وحدة المعالجة المركزية (CPU)، الذاكرة، عرض النطاق الترددي (Bandwidth)، أو جداول الاتصال، مما يؤدي إلى منع المستخدمين الشرعيين من الوصول إلى الخدمة. يعتمد هذا النوع من الهجمات عادةً على مصدر واحد يقوم بإرسال عدد كبير من الطلبات أو الحزم إلى الخادم المستهدف خلال فترة زمنية قصيرة، بحيث يعجز النظام عن معالجتها.

4.1 أنواع هجمات حجب الخدمة (DoS)

4.1.1 هجمات الإغراق بالحزم (Flooding Attacks)

تعتمد هذه الهجمات على إرسال عدد هائل من الحزم إلى النظام المستهدف ومن أنواعها:

✓ SYN Flood

- يستغل آلية المصافحة الثلاثية في بروتوكول TCP
- يرسل المهاجم طلبات اتصال دون إكمال المصافحة
- يؤدي إلى استنزاف جدول الاتصالات في الخادم

✓ ICMP Flood (Ping Flood)

- إرسال عدد كبير من رسائل ICMP
- يؤدي إلى استهلاك عرض النطاق الترددي

4.1.2 هجمات استغلال البروتوكولات (Protocol Attacks)

تعتمد على استغلال نقاط الضعف في تصميم بروتوكولات الشبكة ومن أنواعها:

✓ Smurf Attack

- إرسال طلبات ICMP بعنوان مصدر مزيف
- تضخيم حجم الهجوم عبر شبكات وسيطة

✓ Ping of Death

- إرسال حزم ICMP أكبر من الحجم المسموح
- يؤدي إلى انهيار النظام أو إعادة تشغيله

4.1.3 هجمات الطبقة التطبيقية (Application Layer Attacks)

تستهدف تطبيقات الويب مباشرة ومن أنواعها:

✓ HTTP Flood

- إرسال طلبات HTTP مكثفة
- صعب التمييز بينها وبين المستخدمين الحقيقيين

5. مفهوم هجمات حجب الخدمة الموزع

هجوم حجب الخدمة الموزع (DDoS) هو تطور لهجمات DoS، حيث يتم تنفيذ الهجوم من خلال عدد كبير من الأجهزة المخترقة تعمل معاً في وقت واحد لاستهداف نظام معين. يتم التحكم في هذه الأجهزة عن بُعد عبر خادم تحكم مركزي وفي هذا النوع من الهجمات:

- يتم التحكم في آلاف أو ملايين الأجهزة المصابة
- تُرسل طلبات متزامنة إلى الهدف
- يصبح من الصعب التمييز بين المستخدم الحقيقي والمهاجم

5.1 آلية عمل هجمات DDoS

تمر هجمات DDoS بعدة مراحل رئيسية:

5.1.1 مرحلة الاختراق (Infection)

يقوم المهاجم بإصابة عدد كبير من الأجهزة ببرمجيات خبيثة.

5.1.2 مرحلة التحكم (Command & Control)

يتم ربط الأجهزة المصابة بخادم تحكم مركزي.

5.1.3 مرحلة الهجوم (Attack Launch)

يتم إرسال أوامر للأجهزة لشن الهجوم بشكل متزامن على الهدف.

5.2 أنواع هجمات حجب الخدمة الموزعة (DDoS)

يتم تصنيف هجمات DDoS بناءً على نوع وكمية حركة المرور المستخدمة للهجوم عليه يتم تصنيف هجمات DDoS إلى ثلاث فئات

5.2.1 هجمات الحجم الكبير (Volumetric Attacks)

يستخدم هذا النوع من الهجمات كمية هائلة من حركة المرور تهدف إلى استهلاك عرض النطاق الترددي.. من السهل توليد الهجمات الحجمية من خلال استخدام تقنيات تضخيم بسيطة ومن أنواعها:

UDP Flood ✓

- إرسال حزم UDP عشوائية
- يؤدي إلى تشبع الشبكة

DNS Amplification ✓

- استغلال خوادم DNS مفتوحة
- تضخيم حجم الهجوم عدة مرات

5.2.2 هجمات استنزاف البروتوكولات (Protocol-based Attacks)

يجعل هذا النوع من الهجمات هدفاً يمكن الوصول إليه من خلال استغلال نقطة ضعف في مكدس بروتوكول الطبقة الثالثة والرابعة ومن أنواعها:

SYN Flood الموزع ✓

- آلاف الأجهزة تنفذ SYN Flood في وقت واحد

ACK Flood ✓

- إرسال حزم ACK غير متوقعة
- استنزاف موارد التحقق

5.2.3 هجمات طبقة التطبيقات (Application Layer DDoS)

يستغل هذا النوع من الهجمات نقطة ضعف في حزمة البروتوكولات. هذه الهجمات هي الهجوم الأكثر تعقيداً وهناك صعوبة للتخفيف من حدته ويعتبر أخطر أنواع هجمات حجب الخدمة الموزع ومن أنواعها:

HTTP GET/POST Flood ✓

- محاكاة سلوك المستخدم الحقيقي
- يصعب اكتشافها

Slowloris Attack ✓

- إبقاء الاتصالات مفتوحة لأطول وقت ممكن
- استنزاف موارد الخادم تدريجياً

5.3 الطرق التقليدية للحماية من هجمات حجب الخدمة (DoS/DDoS)

5.3.1 التصفية المعتمدة على القواعد

تعتمد هذه الطريقة على تحديد قواعد ثابتة لتصفية حركة المرور الشبكية، مثل:

- حظر عناوين IP المشبوهة
- تحديد حد أعلى لعدد الطلبات في الثانية
- إسقاط الحزم غير المطابقة لمعايير معينة

هذه الطريقة سهلة التنفيذ ولكنها غير فعالة ضد الهجمات المتغيرة وتتطلب تحديناً مستمراً للقواعد

5.3.2 أنظمة كشف ومنع التسلل التقليدية (IDS/IPS)

تعتمد هذه الأنظمة على التوقيعات (Signatures) وهي فعالة ضد الهجمات المعروفة ويتم استخدامها على نطاق واسع ولكنها:

- غير قادرة على كشف أنواع الهجمات الجديدة
- ارتفاع نسبة الإنذارات الخاطئة
- محدودية الأداء عند الهجمات الضخمة

5.3.3 تحديد المعدل

يتم فرض حد أقصى لعدد الطلبات القادمة من مصدر واحد خلال فترة زمنية معينة وهذا يمكن أن يقلل من الإغراق المفاجئ ولكنه لا يكون فعالاً ضد DDoS متعددة المصادر وأيضاً يمكن أن يؤثر على المستخدمين الشرعيين.

6. حدود الطرق التقليدية

على الرغم من فعالية الأساليب التقليدية في الحد من بعض أنواع هجمات حجب الخدمة، إلا أنها تعاني من محدودية واضحة في مواجهة الهجمات الموزعة والمتطورة، خصوصاً تلك التي تستهدف الطبقة التطبيقية، ضعف في التكيف مع أنواع الهجمات الجديدة وصعوبة التمييز بين المستخدم الحقيقي والمهاجم الذكي لذلك، أصبح من الضروري تطوير حلول ذكية تعتمد على تقنيات التعلم الآلي والتعلم العميق القادرة على التكيف مع الأنماط المتغيرة لهجمات حجب الخدمة. وانطلاقاً من هذه التحديات، تم اقتراح النموذج التجريبي في هذه الدراسة كبديل ذكي يعتمد على تقنيات التعلم العميق، بهدف إلى تحليل حركة مرور الشبكة بطريقة آلية واستخلاص الأنماط الخفية التي يصعب اكتشافها باستخدام القواعد التقليدية. ويتميز النموذج المقترح بقدرته على التعلم من البيانات مباشرة دون الحاجة إلى تعريف صريح لقواعد أو توافيق، مما يمنحه قابلية أعلى للتكيف مع التغيرات المستمرة في سلوك الهجمات.

7. الدراسات السابقة

1- دراسة (Ahmad et al., 2020)

قدمت هذه الدراسة نموذجاً قائماً على الشبكات العصبية العميقة (DNN) للكشف عن هجمات DDoS باستخدام مجموعة بيانات CICIDS2017. اعتمد الباحثون على تقنيات المعالجة المسبقة للبيانات واختيار الخصائص المهمة لتحسين أداء النموذج. وأظهرت النتائج أن النموذج حقق دقة تجاوزت 98%، مع قدرة جيدة على التمييز بين حركة المرور الطبيعية والهجمات الخبيثة. وأشارت الدراسة إلى أن استخدام الشبكات العصبية العميقة يساعد في استخراج الأنماط المعقدة داخل البيانات الشبكية وتحسين كفاءة أنظمة كشف التسلل.

2- دراسة (Kim et al., 2021)

ركزت هذه الدراسة على استخدام نموذج الذاكرة طويلة وقصيرة المدى (LSTM) للكشف عن هجمات DDoS داخل شبكات إنترنت الأشياء (IoT). اعتمدت الدراسة على تحليل التسلسل الزمني لحركة المرور الشبكية، حيث تم تدريب نموذج LSTM على بيانات شبكية متدفقة تحتوي على أنماط هجومية مختلفة. وأظهرت النتائج أن نموذج LSTM حقق أداءً مرتفعاً في اكتشاف الهجمات مقارنةً بالنماذج التقليدية، وذلك بسبب قدرته على الاحتفاظ بالمعلومات الزمنية وتحليل العلاقات المتتالية داخل البيانات.

3- دراسة (Vinayakumar et al., 2019)

هدفت هذه الدراسة إلى مقارنة عدة نماذج من التعلم العميق في مجال كشف التسلل، مثل:

- DNN
- CNN
- LSTM

واستخدم الباحثون مجموعة بيانات CICIDS2017 لتقييم أداء النماذج المختلفة. وأظهرت النتائج أن نموذج LSTM حقق نتائج أفضل في التعامل مع البيانات الزمنية، بينما أظهر نموذج DNN سرعة أكبر في التدريب والتنفيذ. وأكدت الدراسة أن اختيار النموذج المناسب يعتمد على طبيعة البيانات وحجمها ونوع الهجمات المستهدفة.

8. الجانب العملي

8.1 مجموعة البيانات (Dataset)

تم الاعتماد في هذه الدراسة على مجموعة بيانات واقعية تُعرف باسم CICIDS2017، والتي تُعد من أشهر قواعد البيانات المستخدمة في أبحاث الأمن السيبراني. حيث تحتوي مجموعة البيانات على حركة مرور شبكية حقيقية تشمل عدة أنواع من الهجمات:

- DDoS
- DoS
- Brute Force
- Port Scan

وتتضمن عدداً كبيراً من السمات (Features) التي تصف خصائص حركة الشبكة الموضحة بالجدول (8.1).

جدول 8.1 خصائص البيانات

الوصف	الخاصية (Feature)
مدة الاتصال	Flow Duration
عدد الحزم المرسله	Total Fwd packets
عدد الحزم المستلمة	Total Backward packets
معدل نقل البيانات	Flow Bytes/s
معدل الحزم	Flow Packets/s
متوسط طول الحزمة	Packet Length Mean
الانحراف المعياري	Packet Length Std
عدد إشارات SYN	SYN Flag Count
عدد إشارات ACK	ACK Flag Count
متوسط زمن الخمول	Idle Mean
متوسط زمن النشاط	Active Mean

8.2 بيئة التنفيذ والأدوات المستخدمة

تم تنفيذ الجانب العملي باستخدام لغة البرمجة Python لما توفره من مكتبات متخصصة في مجالات التعلم العميق وتحليل البيانات. وقد تم الاعتماد على عدد من المكتبات العلمية القياسية، من أبرزها:

- مكتبة NumPy لتنفيذ العمليات الرياضية ومعالجة البيانات العددية.
- مكتبة Pandas لتنظيم البيانات والتعامل معها في شكل جداول.
- مكتبة Scikit-learn لتنفيذ عمليات تقسيم البيانات وحساب مؤشرات الأداء.
- مكتبة TensorFlow / Keras لبناء وتدريب نموذج الشبكة العصبية العميقة.
- مكتبة Matplotlib لتمثيل النتائج بيانياً عند الحاجة.

وقد تم تنفيذ جميع التجارب على حاسوب شخصي يعمل بنظام تشغيل Windows ، دون الحاجة إلى بنية حوسبية متقدمة، مما يعزز قابلية إعادة تطبيق التجربة.

8.3 المعالجة المسبقة للبيانات (Data Preprocessing)

تُعد مرحلة المعالجة المسبقة من أهم المراحل في بناء نموذج تعلم عميق فعال، حيث تؤثر بشكل مباشر على جودة النتائج.

8.3.1 تنظيف البيانات

- إزالة القيم المفقودة (Missing Values)
- حذف السجلات غير الصالحة

8.3.2 تحويل البيانات

- تحويل القيم النصية إلى رقمية (Encoding)
- تصنيف البيانات إلى :

بيانات طبيعية (Benign)	0	✓
هجوم (Attack)	1	✓

8.3.3 تطبيع البيانات (Normalization)

تم استخدام تقنية StandardScaler لتوحيد نطاق القيم، مما يساعد على تحسين سرعة ودقة التدريب.

8.3.4 تقسيم البيانات

تم تقسيم البيانات إلى:

- 80% بيانات تدريب (Training Set)
- 20% بيانات اختبار (Testing Set)

8.4 تصميم الدراسة

تعتمد هذه الدراسة على استخدام نموذجين من نماذج التعلم العميق، الشبكة العصبية العميقة (Deep Neural Network - DNN) والشبكة العصبية المتكررة من نوع الذاكرة طويلة وقصيرة المدى (Long Short-Term Memory - LSTM). لا يستخدم نموذج DNN لاستخلاص الأنماط من البيانات الثابتة، بينما يتميز نموذج LSTM بقدرته على معالجة البيانات الزمنية وتحليل التسلسل الزمني لحركة المرور الشبكية، مما يجعله أكثر كفاءة في كشف هجمات حجب الخدمة الموزعة (DDoS). تم تدريب كلا النموذجين على نفس مجموعة البيانات لضمان عدالة المقارنة، مع استخدام نفس خطوات المعالجة المسبقة.

8.4.1 نموذج الشبكة العصبية العميقة (Deep Neural Network – DNN)

يتكون هذا النموذج من عدة طبقات متصلة بالكامل (Fully Connected Layers) ، حيث يتم تمرير البيانات عبر هذه الطبقات لاستخلاص الأنماط.

- طبقة إدخال
- ثلاث طبقات مخفية باستخدام دالة تنشيط ReLU
- طبقة إخراج باستخدام Sigmoid

8.4.2 نموذج الشبكة العصبية المتكررة من نوع الذاكرة طويلة وقصيرة المدى – (Long Short-Term Memory – LSTM)

يعد نموذج LSTM من النماذج المتقدمة القادرة على التعامل مع البيانات الزمنية، وهو مناسب لتحليل حركة المرور الشبكية. حيث لديه القدرة على حفظ المعلومات السابقة وتحليل التسلسل الزمني للبيانات وتحسين دقة الكشف ويتكون من:

- طبقة LSTM أولى (64 وحدة)
- طبقة Dropout لتقليل الإفراط في التعلم (Overfitting)
- طبقة LSTM ثانية (32 وحدة)
- طبقة كثيفة (Dense)
- طبقة إخراج

9. تقييم الأداء

بعد الانتهاء من مرحلة التدريب، تم تقييم أداء النموذج باستخدام مجموعة الاختبار غير المستخدمة في التدريب. وقد تم الاعتماد على مجموعة من المقاييس الإحصائية الشائعة في مجال كشف التسلسل، وتُعد هذه المقاييس معيارًا معتمدًا في تقييم أنظمة كشف التسلسل، حيث توازن بين دقة الكشف وتقليل الإنذارات الخاطئة وهي:

9.1 الدقة الكلية (Accuracy)

تشير الدقة الكلية إلى نسبة العينات التي تم تصنيفها بشكل صحيح من إجمالي العينات. أي كم مرة كان قرار النموذج صحيحًا مقارنة بجميع القرارات التي اتخذها وعلى الرغم من أهميتها كمؤشر عام لأداء النموذج، إلا أنها لا تُعد كافية بمفردها في تقييم أنظمة كشف هجمات حجب الخدمة الموزعة، نظرًا لاحتمالية عدم توازن البيانات وخطورة حالات عدم اكتشاف الهجوم.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

9.2 الدقة النوعية (Precision)

تمثل الدقة النوعية نسبة الهجمات الحقيقية من إجمالي الحالات التي صنفتها النموذج كهجمات. وتُعد مؤشرًا على موثوقية إنذارات النظام، حيث يشير انخفاضها إلى ارتفاع معدل الإنذارات الكاذبة، وهو ما قد يؤثر سلبًا على كفاءة أنظمة كشف هجمات حجب الخدمة.

$$Precision = \frac{TP}{TP + FP}$$

9.3 الاسترجاع (Recall)

يقيس الاسترجاع قدرة النموذج على اكتشاف الهجمات الفعلية من إجمالي الهجمات الموجودة في مجموعة البيانات، ويعكس كفاءة النظام في عدم تفويت الهجمات. وتشير قيمة الاسترجاع المتوسطة إلى أن النموذج تمكن من اكتشاف جزء معتبر من الهجمات، إلا أن نسبة غير قليلة منها ما زالت تمر دون كشف.

$$Recall = \frac{TP}{TP + FN}$$

9.4 مقياس F1

يمثل مقياس F1-Score المتوسط التوافقي بين الدقة النوعية والاسترجاع، ويعد من أهم مؤشرات تقييم أداء نماذج كشف هجمات حجب الخدمة الموزعة، خاصة في ظل عدم توازن البيانات. وتشير القيمة المحققة إلى أن النموذج يوفر توازنًا معقولًا بين اكتشاف الهجمات وتقليل الإنذارات الخاطئة.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

حيث أن :

- TP (True Positive): عدد الهجمات التي تم اكتشافها بشكل صحيح
- TN (True Negative): عدد البيانات الطبيعية المصنفة بشكل صحيح
- FP (False Positive): بيانات طبيعية تم تصنيفها كهجوم
- FN (False Negative): هجمات لم يتم اكتشافها

10 النتائج وتحليل الاداء

بعد الانتهاء من تدريب كلا النموذجين باستخدام مجموعة بيانات CICIDS2017 الخاصة بكشف هجمات حجب الخدمة الموزعة (DDoS)، تم اختبار النموذجين على بيانات لم تُستخدم أثناء عملية التدريب بهدف تقييم قدرة هذه النماذج على التعميم وكفاءة الكشف عن الهجمات.

10.1 نتائج نموذج DNN

تم تدريب نموذج الشبكة العصبية العميقة (Deep Neural Network - DNN) باستخدام مجموعة بيانات CICIDS2017 بهدف كشف هجمات حجب الخدمة الموزعة (DDoS)، حيث تم إجراء المعالجة المسبقة للبيانات وتطبيق الخصائص قبل عملية التدريب. وبعد الانتهاء من تدريب النموذج واختباره، تم تقييم أدائه باستخدام مجموعة من المقاييس الإحصائية، وكانت النتائج كما موضحة بالجدول (10.1)

جدول 10.1 نتائج نموذج DNN

المقياس	القيمة
Accuracy	99.20%
Precision	99.40%
Recall	98.90%
F1-Score	99.10%

10.2 تحليل نتائج نموذج DNN

تشير النتائج السابقة إلى أن نموذج DNN حقق أداءً مرتفعاً في عملية تصنيف البيانات الشبكية، حيث بلغت الدقة الكلية حوالي:

Accuracy=99.20%

مما يدل على قدرة النموذج على التمييز بين حركة المرور الطبيعية والهجمات الإلكترونية بدرجة عالية من الكفاءة. كما حقق النموذج قيمة Precision مرتفعة بلغت:

Precision=99.40%

وهو ما يشير إلى انخفاض عدد الإنذارات الكاذبة التي يصدرها النظام أثناء عملية الكشف. أما قيمة الاسترجاع Recall فقد بلغت:

Recall=98.90%

مما يدل على قدرة النموذج على اكتشاف معظم الهجمات الموجودة داخل البيانات. في حين بلغت قيمة F1-Score حوالي:

F1=99.10%

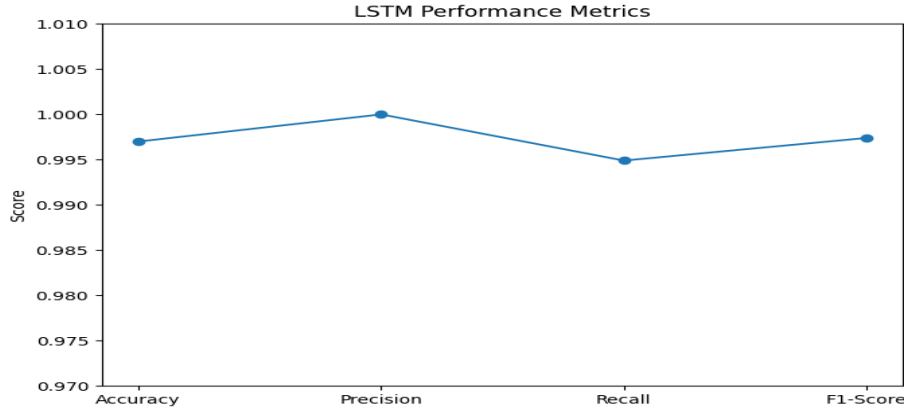
وهو ما يعكس وجود توازن جيد بين الدقة والاسترجاع. وتوضح هذه النتائج أن نموذج DNN يُعد نموذجاً فعالاً في كشف هجمات DDoS

10.3 نتائج نموذج LSTM

الجدول 10.2 يوضح قيم مقاييس الأداء الخاصة بالنموذج LSTM

جدول (10.2) نتائج نموذج LSTM

المقياس	القيمة
Accuracy	99.70%
Precision	100%
Recall	99.49%
F1-Score	99.74%



شكل 10.1 مقاييس أداء نموذج LSTM

يوضح الشكل السابق أداء نموذج الذاكرة طويلة وقصيرة المدى (LSTM) باستخدام مقاييس التقييم المختلفة، حيث حقق النموذج قيمة مرتفعة جداً في جميع المقاييس الإحصائية المستخدمة في الدراسة. وقد بلغت الدقة الكلية (Accuracy) حوالي 99.70%، مما يدل على قدرة النموذج العالية في تصنيف حركة المرور الشبكية بصورة صحيحة. كما حقق النموذج قيمة Precision بلغت 100%، وهو ما يشير إلى انخفاض الإنذارات الكاذبة بشكل كبير.

كذلك أظهرت نتائج الاسترجاع (Recall) ومقياس F1-Score أداءً مرتفعاً، مما يؤكد كفاءة نموذج LSTM في اكتشاف هجمات DDoS وتحقيق توازن جيد بين دقة التصنيف واكتشاف الهجمات الفعلية.

10.4 تحليل النتائج LSTM

تشير النتائج السابقة إلى أن نموذج LSTM استطاع تحقيق كفاءة عالية جداً في كشف هجمات DDoS، ويُعزى ذلك إلى قدرة النموذج على تحليل الأنماط الزمنية لحركة المرور الشبكية والتعرف على السلوك غير الطبيعي داخل البيانات.

✓ الدقة الكلية (Accuracy)

حقق النموذج دقة كلية بلغت 99.70%، وهي نسبة مرتفعة تشير إلى نجاح النموذج في تصنيف معظم البيانات بشكل صحيح. ويعكس ذلك قدرة نموذج LSTM على تعلم الأنماط المعقدة الموجودة داخل البيانات الشبكية.

✓ الدقة النوعية (Precision)

بلغت قيمة الدقة النوعية 100%، مما يعني أن جميع الاتصالات التي صنفتها النموذج كهجمات كانت بالفعل هجمات حقيقية، أي أن النموذج لم ينتج أي إنذارات كاذبة (False Positives). وتعد هذه النتيجة مهمة جداً في أنظمة كشف التسلل، لأن تقليل الإنذارات الكاذبة يساعد في رفع كفاءة النظام وتقليل العبء على مسؤولي الشبكات.

✓ الاسترجاع (Recall)

حقق النموذج قيمة استرجاع بلغت 99.49%، مما يدل على قدرة عالية في اكتشاف الهجمات الفعلية وتقليل عدد الهجمات غير المكتشفة.

وتشير هذه النتيجة إلى كفاءة نموذج LSTM في تحليل التسلسل الزمني لحركة المرور الشبكية واكتشاف الأنماط المرتبطة بهجمات DDoS.

✓ مقياس F1-Score

بلغت قيمة F1-Score حوالي 99.74% وهي قيمة مرتفعة تعكس وجود توازن ممتاز بين الدقة النوعية والاسترجاع، مما يؤكد استقرار النموذج وكفاءته العالية في التصنيف.

10.5 تحليل مصفوفة الالتباس (Confusion Matrix)

كانت مصفوفة الالتباس للنموذج كما يلي:

$$\begin{bmatrix} 417 & 0 \\ 3 & 580 \end{bmatrix}$$

ويُفسر ذلك كما يلي:

- تم تصنيف 417 اتصالاً طبيعياً بشكل صحيح .
- تم اكتشاف 580 هجمة DDoS بشكل صحيح .
- لم يتم تسجيل أي إنذار كاذب .
- أخفق النموذج في اكتشاف 3 هجمات فقط .

وتؤكد هذه النتائج كفاءة النموذج المقترح في كشف هجمات DDoS بدقة مرتفعة جداً.

11 المقارنة

11.1 المقارنة بين نموذج DNN ونموذج LSTM

لإظهار كفاءة نماذج التعلم العميق في كشف هجمات حجب الخدمة الموزعة (DDoS)، تم إجراء مقارنة بين نموذج الشبكة العصبية العميقة (DNN) ونموذج الذاكرة طويلة وقصيرة المدى (LSTM) باستخدام نفس مجموعة البيانات ونفس معايير التقييم.

أظهرت النتائج الموضحة في الجدول (11.1) أن كلا النموذجين حقق أداءً مرتفعاً في عملية التصنيف، إلا أن نموذج LSTM تفوق بشكل طفيف على نموذج DNN في معظم المقاييس، ويرجع ذلك إلى قدرة LSTM على تحليل البيانات الزمنية والتسلسلات المتعاقبة لحركة المرور الشبكية، وهو ما يجعله أكثر ملاءمة لاكتشاف الأنماط الديناميكية المرتبطة بهجمات DDoS.

جدول (11.1) مقارنة نتائج LSTM و DNN

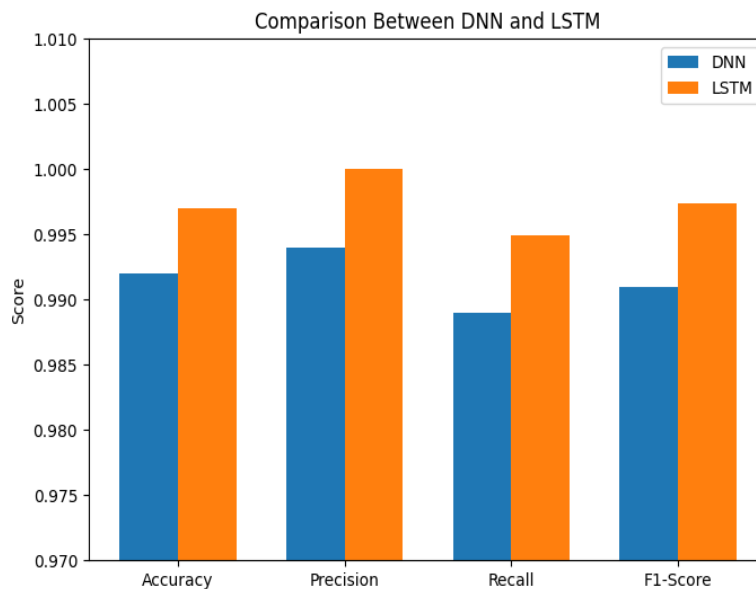
المقياس	DNN	LSTM
الدقة الكلية (Accuracy)	0.9920	0.9970
الدقة النوعية (Precision)	0.9940	1.0000
الاسترجاع (Recall)	0.9890	0.9949
مقياس F1	0.9910	0.9974

11.2 تحليل المقارنة

تشير النتائج الواردة في الجدول السابق إلى أن نموذج LSTM حقق أفضل أداء مقارنةً بنموذج DNN، حيث بلغت الدقة الكلية للنموذج حوالي 99.70%، وهي نسبة مرتفعة تدل على قدرة النموذج على التمييز بين حركة المرور الطبيعية والهجمات الإلكترونية بكفاءة عالية.

كما حقق نموذج LSTM قيمة Precision بلغت 100%، مما يعني أن جميع العينات التي تم تصنيفها كهجمات كانت صحيحة فعلياً، دون وجود إنذارات كاذبة تقريباً، وهو أمر بالغ الأهمية في أنظمة كشف التسلسل والشبكات الأمنية. أما بالنسبة لمقياس Recall فقد بلغ 99.49%، مما يشير إلى قدرة النموذج على اكتشاف معظم الهجمات الموجودة داخل البيانات، مع فقدان عدد محدود جداً من العينات الضارة. كذلك حقق النموذج قيمة F1-score مرتفعة بلغت 99.74%، مما يعكس التوازن الممتاز بين الدقة والاسترجاع.

في المقابل، حقق نموذج DNN نتائج جيدة أيضاً، إلا أن أدائه كان أقل قليلاً من نموذج LSTM، ويرجع ذلك إلى أن DNN يعالج البيانات بصورة ثابتة دون الاستفادة الكاملة من العلاقات الزمنية بين الحزم الشبكية المتتابعة. وبناءً على النتائج السابقة، يمكن الاستنتاج أن نموذج LSTM يُعد أكثر كفاءة وملاءمة لكشف هجمات DDoS مقارنةً بنموذج DNN، خصوصاً في البيئات الشبكية التي تعتمد على تدفقات بيانات متسلسلة ومتغيرة مع الزمن.



شكل 11.1 مقارنة أداء نموذج DNN ونموذج LSTM

12 الخلاصة

تناولت هذه الدراسة تطوير نموذج ذكي للكشف عن هجمات حجب الخدمة الموزعة (DDoS) اعتماداً على تقنيات التعلم العميق، وذلك من خلال بناء إطار تجريبي قائم على مقارنة أداء نموذجين رئيسيين هما الشبكة العصبية العميقة (DNN)

والشبكة العصبية المتكررة (LSTM) وقد تم استخدام مجموعة بيانات واقعية (CICIDS2017) مع تطبيق مجموعة متكاملة من خطوات المعالجة المسبقة، شملت تنظيف البيانات، وتحويلها، وتطبيعها، وتقسيمها إلى بيانات تدريب واختبار. أظهرت النتائج النموذج LSTM حقق نتائج متقدمة على نموذج DNN في جميع مقاييس التقييم المعتمدة، بما في ذلك الدقة الكلية، والدقة النوعية، والاسترجاع، ومعامل F1، مما يعكس كفاءة عالية في اكتشاف الهجمات وتقليل الأخطاء. وتبرز هذه النتائج أهمية اعتماد النماذج القائمة على تحليل التسلسل الزمني في معالجة بيانات الشبكات، لما لها من قدرة على التقاط الأنماط الديناميكية المعقدة المرتبطة بسلوك الهجمات الإلكترونية.

13 الخاتمة

خلصت هذه الدراسة إلى أن تقنيات التعلم العميق تمثل أحد أهم الاتجاهات الحديثة في مجال الأمن السيبراني، خاصة في كشف هجمات حجب الخدمة الموزعة (DDoS) وقد أثبت نموذج LSTM تفوقه الواضح على نموذج DNN، وذلك بفضل قدرته على تحليل البيانات الزمنية واستيعاب العلاقات المتتالية بين الأحداث داخل حركة المرور الشبكية. كما أظهرت النتائج أن جودة البيانات وفعاليتها مراحل المعالجة المسبقة تلعب دورًا حاسمًا في تحسين أداء النماذج، إلى جانب أهمية اختيار الخصائص المناسبة وبنية النموذج الملائمة. وبناءً على ذلك، يمكن التأكيد على أن دمج نماذج التعلم العميق، وخاصة النماذج الزمنية، في أنظمة كشف التسلسل يسهم بشكل فعال في تعزيز أمن الشبكات، ورفع كفاءة الأنظمة الدفاعية في مواجهة التهديدات السيبرانية المتزايدة.

14 المراجع

1. عبد الله، محمد أحمد. (2021) "استخدام تقنيات التعلم العميق في كشف الهجمات السيبرانية"، *المجلة العربية لتقنية المعلومات*.
2. الحربي، خالد بن سعود. (2020) "أمن الشبكات وهجمات حجب الخدمة"، دار النشر الأكاديمي.
3. عمر سلام، "تحسين كشف وتخفيف هجمات DDoS باستخدام تقنيات التعلم العميق"، رسالة ماجستير، جامعة ديالى، العراق، 2024.
4. *Deep Learning*. MIT Press. Goodfellow, I., Bengio, Y., & Courville, A. (2016).
5. "Early detection of DDoS attacks against SDN S. M. Mousavi and M. St-Hilaire (2018). *Journal of Network and Computer controllers using machine learning techniques, Applications*, 104, 61–74.
6. "Deep learning models for cyber security in IoT networks," M. Roopak, G. Y. Tian, and J. Chambers (2019). *IEEE Access*, 7, 47374–47384.
7. I. Sharafaldin, A. H. Lashkari, and A. A. Ghorbani, "Toward Generating a New Intrusion Detection Dataset and Intrusion Traffic Characterization," *Proceedings of the 4th International Conference on Information Systems Security and Privacy (ICISSP)*, pp. 108–116, 2018.
8. M. Ahmad, A. Shahid, and S. Khan, "Deep Neural Network Based DDoS Detection System Using CICIDS2017 Dataset," *International Journal of Computer Networks and Communications*, vol. 12, no. 4, pp. 55–67, 2020.
9. N. Shone, T. N. Ngoc, V. D. Phai, and Q. Shi, "A Deep Learning Approach to Network Intrusion Detection," *IEEE Transactions on Emerging Topics in Computational Intelligence*, vol. 2, no. 1, pp. 41–50, 2018.
10. J. Kim, H. Kim, and M. Shim, "LSTM-Based DDoS Detection for IoT Networks," *Journal of Information Security and Applications*, vol. 58, pp. 102–115, 2021.
11. R. Vinayakumar, K. Soman, and P. Poornachandran, "Evaluating Deep Learning Approaches for Network Intrusion Detection Systems," *IEEE Access*, vol. 7, pp. 41520–41535, 2019.