

تقدير القناة في الجيل الخامس باستخدام تقنيات التعلم العميق

م. ليلى محمد إسماعيل *

د. محمد حيدر نصر **

أ.د. فادي جودت غصنه ***

(تاريخ الإيداع 2023 /9/7 – تاريخ النشر 2023 /12/3)

□ ملخص □

تُعدّ الشبكة العصبونية الالتفافية (Convolutional Neural Network (CNN)، أحد أمثلة التعلم العميق والتي تمّ استخدامها للتنبؤ وتقدير القناة في شبكة الجيل الخامس التي تستخدم نظام الهوائيات MIMO (تعدد الهوائيات في الدخل والخرج) مع قناة متعددة المسارات (multi paths) تخضع لتأثيرات دوبلر والضجيج. تمت الدراسة من خلال توليد بيانات متبادلة في شبكة جيل خامس وتقدير القناة بالطريقة العملية، من ثمّ تم إجراء عملية استيفاء خطي linear interpolation للقناة، ليتم بعدها تقدير القناة من خلال شبكة CNN. تضمّن هذا العمل دراسة تقنيات تقدير القناة في الجيل الخامس من الاتصالات الخليوية، حيث تمّت مقارنة القناة الفعلية بالحالة التي يتم فيها استخدام تقنيات التعلم العميق (الشبكات العصبونية) لتقدير القناة، بالإضافة إلى حالة التقدير باستخدام التقنيات التقليدية. أظهرت النتائج العددية لمتوسط معدل الخطأ للحالات المدروسة أنّ استخدام تقنيات التعلم العميق يلعب دوراً بالغ الأهمية في تقدير قناة الجيل الخامس كونها تتميز بالدقة الفائقة، التعقيد المنخفض، ومعدل الخطأ المنخفض. تمّ استخدام البيئة البرمجية MATLAB لإجراء عمليات المحاكاة. **الكلمات المفتاحية:** الجيل الخامس، تقدير القناة، التعلم العميق مع الجيل الخامس، الشبكة العصبونية الالتفافية

* طالبة دكتوراه-كلية هندسة تكنولوجيا المعلومات والاتصالات-جامعة طرطوس-طرطوس-سوريا

** استاذ مساعد-كلية هندسة تكنولوجيا المعلومات والاتصالات-جامعة طرطوس-طرطوس-سوريا

* استاذ-كلية هندسة تكنولوجيا المعلومات والاتصالات-جامعة طرطوس-طرطوس-سوريا

Channel estimation in the fifth generation using deep learning techniques

Eng. Laila Esmaeil*
Dr. Mohammad nasr**
Dr. Fadi ghosna***

(Received 7/9/2023.Accepted 3/12/2023)

□ABSTRACT □

An example of deep learning is a Convolutional Neural Network (CNN), which has been used for prediction and channel estimation in a 5G network that uses a MIMO (multi-paths) antenna system subject to Doppler and noise effects.

The study was carried out by generating mutual data in a fifth-generation network and estimating the channel in a practical way. Then, a linear interpolation process was performed for the channel, after which the channel was estimated through a CNN network.

This work included a study of channel estimation techniques in the fifth generation of cellular communications, where the actual channel was compared to the case in which deep learning techniques (neural networks) are used to estimate the channel, in addition to the case of estimation using traditional techniques.

Numerical results of the Mean Squared error for the studied cases showed that the use of deep learning techniques plays a very important role in estimating the fifth-generation channel as it is characterized by high accuracy, low complexity, and low error rate.

The MATLAB software environment was used to perform the simulations.

Key Words: The fifth generation 5G, channel estimation, the deep learning with 5G, CNN.

*Phd Student, Faculty of Information and Communication Technology, University of Tartous, Syria.

**Associate Professor, Faculty of Information and Communication Technology, University of Tartous, Syria.

***Professor, Faculty of Information and Communication Technology, University of Tartous, Syria.

1- مقدمة

تتجه معظم دول العالم نحو بناء مجتمع ذكي متكامل في كل مناحي الحياة، وذلك من خلال نقل مفهوم إنترنت الأشياء (Internet of Things (IoT) من الأفكار النظرية إلى حيّز التطبيق العملي، المفهوم الجديد الذي يشمل تطور في أنواع الأجهزة الذكية والأنظمة والتقنيات والتطبيقات. إن مفهوم إنترنت الأشياء يحتاج إلى نظام اتصالات يؤمن معدلات نقل عالية جداً، جودة مرتفعة للخدمات المُقدّمة، وتأخير منخفض للغاية. لذا كان نظام اتصالات الجيل الخامس الخلوي هو الاقتراح الأفضل لتحقيق الأهداف المرجوة من IoT [1].

تمّ تطوير تكنولوجيا الجيل الخامس واستخدامها لتلبية احتياجات الاتصالات المتنقلة، خاصةً مع النمو السريع في طلب المستخدمين على التطبيقات الحديثة فائقة الدقة وعلى محتوى الوسائط السمعية والبصرية عالية الجودة مثل 8K/4K، VR/AR، حيث أصبحت خدمات البث متنوعة ومتطورة وأصبح من الصعب تلبية الطلب باستخدام الشبكات الحالية. وعززت التكنولوجيا الجديدة الرقمنة والشبكات والذكاء في المجالات المختلفة، فشبكات 5G تتمتع بمزايا عديدة أهمها: السرعة العالية، الموثوقية الكبيرة، والتأخير المنخفض جداً.

أظهر التعلم العميق (deep learning) أدواراً مهمة في تحسين أداء النظام وتقليل التعقيد الحسابي لشبكات الجيل الخامس وما بعدها. تمّ في هذا العمل، دراسة طريقة جديدة لتقدير القناة في نظام الجيل الخامس بمساعدة تقنية من تقنيات التعلم العميق، وهي الشبكة العصبونية الالتفافية (Convolutional Neural Network (CNN)، يتم تحقيق هذا الهدف من خلال استخدام نظام MIMO (متعدد الهوائيات في الدخل والخرج) مع قناة متعددة المسارات (multi paths channel) لمحاكاة شبكات 5G تحت تأثيرات دوپلر. تظهر النتائج العددية تفوق طريقة تقدير القناة بمساعدة التعلم العميق المقترحة على طرق تقدير القناة الأخرى من حيث متوسط مربع الخطأ (Mean Squared Error (MSE) [1]

2- هدف البحث

هدف البحث إلى تقدير القناة في نظام الجيل الخامس للاتصالات الخلوية على ثلاث حالات هي:

١- تقدير القناة (الخطي)

٢- تقدير القناة باستخدام الشبكات العصبونية (التعلم العميق)

٣- التقدير العملي للقناة

حيث تمّ قياس ومقارنة متوسط مربع الخطأ (Mean Squared Error (MSE) لكل حالة من الحالات السابقة.

3- طرائق البحث ومواده

تمّ إنجاز هذا البحث بالاعتماد على دراسات ومراجع وأبحاث علمية حديثة متخصصة في أنظمة الاتصالات الخلوية وبالأخص الجيل الخامس الخلوي وتقنياته وخصائصه وميزاته. أُخِذَت نتائج هذه الأبحاث بعين الاعتبار، حيث استخدمت البيئة البرمجية MATLAB في برمجة النظام المدروس وعرض نتائجه.

٣- التعلّم الآلي:

تعمل تقنيات التعلّم الآلي على دعم العديد من جوانب المجتمع الحديث: من عمليات البحث على الويب، إلى تصفية المحتوى على الشبكات الاجتماعية، إلى التوصيات على مواقع التجارة الإلكترونية، وهي موجودة بشكل متزايد في المنتجات الاستهلاكية مثل الكاميرات والهواتف الذكية. تُستخدم أنظمة التعلم الآلي لتحديد الأشياء في الصور، ونسخ

الكلام إلى نص، ومطابقة الأخبار أو المنشورات أو المنتجات مع اهتمامات المستخدمين، وتحديد نتائج البحث ذات الصلة. على نحو متزايد، تُستخدم هذه التطبيقات فئة من التقنيات تسمى التعلّم العميق. [2]

يسمح التعلّم العميق للنماذج الحسابية، المكونة من طبقات معالجة متعددة، بتعلم تمثيل البيانات بمستويات متعددة من التجريد. لقد حسّنت هذه الأساليب بشكل كبير من التقنيات الأحدث في التعرف على الكلام، والتعرف البصري على الأشياء، واكتشاف الأشياء والعديد من المجالات الأخرى مثل اكتشاف الأدوية وعلم الجينوم. يكتشف التعلّم العميق البنية المعقدة في مجموعات البيانات الكبيرة باستخدام خوارزمية (backpropagation) للإشارة إلى كيفية قيام الآلة بتغيير بارامترات الداخلية - المُستخدمة لحساب التمثيل - في كل طبقة من التمثيل في الطبقة السابقة. أحدثت الشبكات الالتفافية العميقة (Deep convolutional nets) تقدّم في معالجة الصور والفيديو والكلام والصوت، في حين أن الشبكات التكرارية recurrent nets سلّطت الضوء على البيانات المتسلسلة مثل النص والكلام. [2]

١-٣ خوارزميات الشبكة العصبونية:

الشبكة العصبونية أو العصبية هي عبارة عن ربط بين العقد والخلايا العصبية الاصطناعية، حيث تقوم كل خلية عصبية بتنفيذ تعليمات لمنطقة معينة [3]. تتفاعل العقد دائماً مع واحدة أو أخرى لنقل المعلومات، حيث تحصل كل عقدة على معلومات أو وظائف العمليات الأخرى التي يتم إجراؤها وتحافظ على المضي قدماً. كان هذا التدفق معروفاً باسم وظيفة /تابع/ التنشيط Activation function والذي يمكنه نقل المدخلات من مخرجات كانت بالفعل مدخلات من عقدة أخرى سابقة. [3]

أنصاف التعلّم العميق في خوارزميات الشبكة العصبونية: [4]

١- Multi-layer Perceptron: وهي الشبكات العصبونية الأساسية، تتعلم العلاقة بين البيانات الخطية وغير الخطية والتي تحتوي أيضاً على شبكات تغذية أمامية، حيث تتعامل بشكل أساسي مع مهام التنشيط غير الخطية وحساب الفشل من خلال تابع الضياع الطبيعي (Log Loss) أو مربع متوسط الخطأ Mean Square error، حيث يتم قياس متوسط مربع الخطأ MSE بشكل شائع كمعامل مهم في شبكات التعلّم العميق.

٢- الشبكات العصبونية الالتفافية Convoluted Neural Networks: يمكن مقارنة شبكات CNN في الأجزاء النموذجية من الشبكات العصبونية، ولكن تم إنشاء البنية المعمارية بشكل أساسي لمعالجة الصور، يتم تنظيم طبقات شبكات CNN في ثلاثة أبعاد (العرض والارتفاع والعمق). هذه الشبكات قابلة للتكيف بشكل خاص مع البيانات ذات الأبعاد، إدراك الكائنات objects recognition، وفحص الصورة بواسطة بنى الخلايا العصبونية متعددة الأوجه. تعد شهرة التعلّم العميق واحدة من القضايا الرئيسية لشبكات CNN.

٣- الشبكات العصبونية التكرارية Recurrent Neural Network RNNs: هي شبكة ذات تغذية أمامية مع حلقات متقطعة من الذاكرة، تعمل على مبدأ حفظ ناتج طبقة معينة وإعادتها إلى المدخلات من أجل التنبؤ بإخراج الطبقة.

- يبين الشكل (١) بعض الأمثلة عن استخدامات التعلم العميق: [5]
- الروبوتات والسيارات ذاتية القيادة Robots and Self Driving Cars.
 - معالجة اللغات الطبيعية Natural Language Processing.
 - تمييز الكلام Speech Recognition
 - تمييز الصور والكلام Image recognition



الشكل (١) تطبيقات التعلم العميق

٣-١-١ شبكات CNN

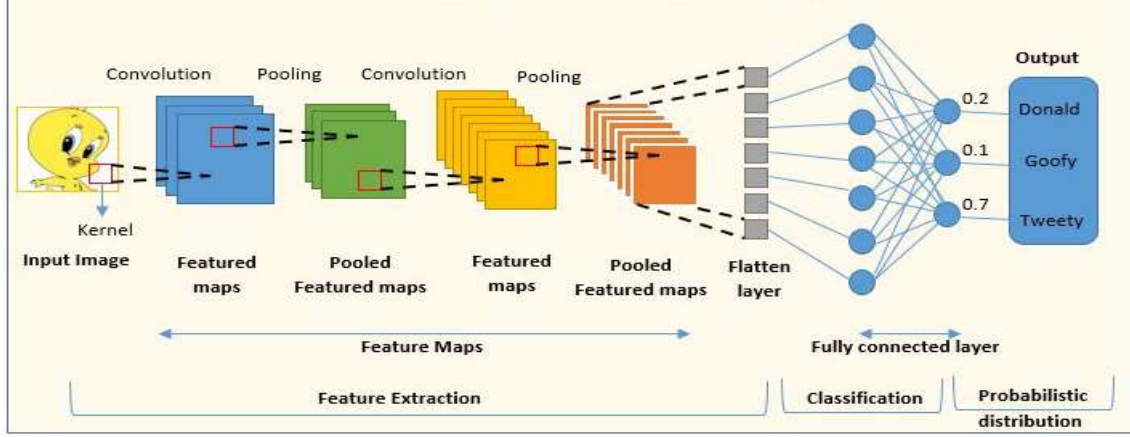
من بين أبنى المعمارية المختلفة للتعلم العميق، هناك نوع خاص من الشبكات العصبونية المتعددة الطبقات للبيانات المكانية هي الشبكة العصبونية الالتفافية "ConvNet" "CNN" Convolutional Neural Network [6]. تتكون الشبكة العصبونية الالتفافية التقليدية من كتل (Blocks) مفردة أو متعددة من طبقات الالتفاف Convolution layers والتجميع pooling layers، تليها طبقة واحدة أو عدة طبقات متصلة بالكامل (fully connected (FC) layers) ومن ثم طبقة الخرج output layer.

الطبقة الالتفافية هي نواة البناء الأساسية لشبكة CNN. تهدف هذه الطبقة إلى تعلم تمثيل الخصائص (المميزات) الخاصة بالدخل. [6]

تتكون الطبقة الالتفافية من عدة نوى التفافية قابلة للتعلم أو مرشحات تُستخدم لحساب خرائط الميزات المختلفة. كل وحدة من خريطة المعالم متصلة بمجال في الطبقة السابقة. يتم إنتاج خريطة المعالم (الميزات) الجديدة عن طريق التفاف المدخلات مع النواة ومن ثم تطبيق تابع التنشيط غير الخطي على نتيجة الالتفاف، حيث تقلل خاصية مشاركة البارامترات للطبقة الالتفافية من تعقيد النموذج.

تأخذ طبقة التجميع أو أخذ العينات الفرعية كمية صغيرة من المخرجات الالتفافية كمدخلات وتختزلها لإنتاج خرج واحد، حيث توجد تقنيات مختلفة لأخذ العينات الفرعية مثل التجميع الأعظمي max pooling، والتجميع الأصغري min pooling، والتجميع المتوسط average pooling، حيث يقلل التجميع من عدد البارامترات التي يجب حسابها بالإضافة إلى أنه يجعل ترجمة الشبكة ثابتة (غير متغيرة). [6]

يتكون الجزء الأخير من CNN أساساً من طبقة FC واحدة أو أكثر توجد عادةً في الشبكة العصبونية المغذية، حيث تأخذ طبقة FC المدخلات من طبقة التجميع النهائية أو الطبقة الالتفافية وتولد الخرج النهائي لشبكة CNN.



الشكل (٢) آلية عمل شبكة CNN

في الوقت الحاضر، ظهرت CNN كآلية لتحقيق نتيجة واعدة في العديد من التطبيقات القائمة على رؤية الكمبيوتر مثل تصنيف الصور، اكتشاف الأشياء، اكتشاف الوجوه، التعرف على الكلام، التعرف على السيارات، التعرف على تعابير الوجه، والتعرف على النص وغيرها الكثير. [6]

3-1-2 طبقات الشبكة العصبونية الالتفافية:

• الطبقة الالتفافية (Convolutional layer):

عملية الالتفاف هي إحدى اللبّات الأساسية للشبكة العصبونية الالتفافية. تتكون بارامترات الطبقة الالتفافية من مجموعة من المرشحات القابلة للتعلّم (النوى kernels)، حيث كل مرشح يكون صغير مكانياً (على طول العرض والارتفاع)، ولكنه يمتد من خلال العمق الكامل لحجم الدخل. قد تكون أحجام المرشحات النموذجية بحجم 3×3 ، 5×5 ، 7×7 . يتوافق البعد الثالث للمرشح مع عدد القنوات في الدخل. أثناء الانتشار الأمامي، يقوم كل مرشح بإجراء التفاف على حجم الدخل عبر العرض والارتفاع ويحسب الجداء النقطي dot products بين مدخلات المرشح والمدخلات في أي موضع، ويتبع هذا تابع تنشيط لا خطي (sigmoid، tanh، ReLU، وما إلى ذلك)، تسمى المخرجات الناتجة بخرائط الميزات feature maps (المعروفة أيضاً باسم خريطة التنشيط) والتي تعطي استجابات المرشح في كل موضع مكاني. يتم تكديس خرائط التنشيط هذه على طول بُعد العمق وينتج حجم الخرج الذي يعتمد على

ثلاث بارامترات: العمق والخطوة والحشو padding. [7].

■ العمق depth: يمثل عمق حجم الخرج عدد المرشحات المستخدمة في عملية الالتفاف، حيث يتعلم كل مرشح شيئاً مختلفاً في الدخل، الحواف، النقاط، والألوان.

■ الخطوة stride: هي عدد الخطوات التي نقوم بتحريك المرشح فيها في الإدخال، فمثلاً عندما تكون الخطوة 1، فإننا نقوم بتحريك المرشح بمقدار بكسل واحد في كل مرة، عندما تكون الخطوة 2، تنزلق المرشحات 2 بكسل في كل مرة، حيث سيؤدي ذلك إلى إنتاج أحجام خرج أصغر مكانياً.

■ الحشو Padding: يسمح الحشو بالتحكم في حجم الخرج، فعند تطبيق الالتفاف على الدخل، يقل حجم الخرج وبالتالي يؤدي إلى فقدان المعلومات. لتجنب ذلك، نقوم بتعبئة (حشو) الحجم المُدخل بالأصفر حول الحدود. هناك خياران شائعان هما الالتفاف المحقق valid convolution والالتفاف المشابه same convolution، فالالتفاف المحقق يعني عدم وجود حشو، الالتفاف المشابه يعني أن حجم المخرجات يظل كما هو لحجم الإدخال.

يتم حساب حجم الخرج بالطريقة التالية: [8]

$$(n + 2p - f) / s + 1 \quad (1)$$

حيث:

n: عدد المرشحات.

p: كمية الحشو.

f: حجم المرشح.


s: الخطوة.

● طبقة التجميع Pooling layer

غالباً ما تستخدم شبكات CNN طبقة التجميع بعد طبقات الالتفاف، وتتمثل وظيفتها في تقليل الأبعاد، والتي يشار إليها أيضاً بأخذ العينات الفرعية أو الاختزال، والبارامترات التشعبية لطبقة التجميع تمثل الحجم والخطوات، حيث أكثر طبقات التجميع شيوعاً هي بحجم مرشح ٢ وبخطوة ٢.

هناك نوعان شائعان من طبقات التجميع هما التجميع الأعظمي max pooling والتجميع المتوسط average pooling، حيث يتم أخذ القيم الأعظمية والمتوسطة، ويتم استخدام Max pooling غالباً أكثر من التجميع المتوسط. [8]

يوضح الشكل (3) طبقة التفاف متبوعة بطبقة تجميع.




الشكل (٣) طبقة التفاف متبوعة بطبقة تجميع

● Fully Connected layer

بعد عدة طبقات التفاف وتجميع، تنتهي شبكة CNN عموماً بعدة طبقات متصلة بالكامل FC. يتم تحويل خرج هذه الطبقات إلى متجه ثم تُضاف عدة طبقات عصبونية.

عادةً ما تكون الطبقات المتصلة تماماً هي الطبقات القليلة الأخيرة من البنية كما هو موضح في الشكل (٤) الذي يوضح طبقتان التفافيتان تتبعهما طبقة متصلة بالكامل، ويمكن تطبيق تقنية التسوية في الطبقات المتصلة تماماً لمنع فرط التخصص. تحتوي الطبقة النهائية المتصلة بالكامل في البنية المعمارية على الكمية ذاتها من الخلايا العصبية في الخرج مثل عدد الفئات التي يجب التعرف عليها. [8]



الشكل (٤) طبقتان التفاضلتان تتبعهما طبقة متصلة بالكامل

٤- تقدير القناة:

في جميع أنظمة الاتصالات، يتم نقل البيانات من المصدر إلى الوجهة على شكل إشارات، تُعبّر هذه الإشارات وسطاً مختلفاً يمكن أن يكون سلكياً أو لاسلكياً. تُعد الأسلاك النحاسية أو الألياف مثاليين على الوسط السلكي بينما الهواء هو وسيط لاسلكي، تسمى هذه الوسائط أيضاً بالقناة. عندما تمر إشارة من القناة، فإنها تتشوه من الضجيج أو من الإشارات الأخرى التي تعبر نفس القناة، هذا يعني أنه عند استقبال الإشارة في وجهتها الهدف، قد تعاني من أخطاء. لذلك، من أجل إزالة تأثيرات الضجيج والتشويه من الإشارة المستقبلية، يجب اكتشاف خصائص القناة وتسمى هذه العملية بتقدير القناة (channel estimation) [9].

نظراً للإنتاجية العالية والتأخير المنخفض والموثوقية والاتصالات الهائلة، أصبحت شبكات 5G وما بعدها شائعة في عصر الاتصالات اللاسلكية عالية السرعة. يعاني الإرسال متعدد المسارات وذو التردد العالي من التوهين والتأخير والتشوه الذي يؤثر على إرسال الإشارة، لذا من الضروري معرفة أو تقدير القناة لإعادة بناء الإشارة الأصلية. حيث يعتبر تقدير القناة الفعال هو عنصر حاسم في جهاز الاستقبال.

تتكون عملية تقدير القناة من عدة خطوات، أولاً يتم إنشاء نموذج رياضي للقناة، ثم يتم إرسال إشارة يعرفها كل من المرسل والمستقبل عبر القناة. عندما يستقبل جهاز الاستقبال الإشارة، فإنها بالطبع مشوهة وتحتوي على ضجيج من القناة، ولكن المستقبل يعرف أيضاً الإشارة الأصلية، وبالتالي يمكنه مقارنة الإشارة الأصلية والإشارة المستقبلية لاستخراج خصائص القناة والضجيج المضاف إلى الإشارة المرسل في القناة.

عادةً ما تسمى الإشارة المرسل والمعروفة من قبل كل من المرسل والمستقبل بالإشارة المرجعية

(reference signal) أو الإشارة التجريبية (pilot signal) [9].

يُعد تقدير القناة في أنظمة الجيل الخامس 5G NR عملية مختلفة عن تلك في أنظمة الجيل الرابع LTE "Long-Term Evolution"، حيث يتمثل الاختلاف الرئيسي في أن 5G NR لا يتضمن إشارات مرجعية خاصة بالخلية من أجل الوصلة الهابطة (DL)، بينما يعتمد 5G NR فقط على إشارات مرجعية خاصة بالمستخدم لفك التعديل "demodulation reference signals" DMRS، المعروفة أيضاً باسم (pilots الرموز التجريبية) عند تقدير القناة.

لا يتم إرسال هذه الرموز المرجعية pilots ما لم تكن هناك بيانات لإرسالها، الأمر الذي يحسن أداء طاقة الشبكة ويقلل التداخل.

في أنظمة OFDM، تعمل كل موجة حاملة فرعية كقناة مستقلة طالما لم يبق هناك تداخل بين الموجات الحاملة (ICI) في الإشارة المتزامنة. تتوفر عدة خيارات لتقدير القناة منها تسلسل التدريب Training

Sequence والإشارة المرجعية الفردية Individual Pilots ، ويعتمد الاختيار بين الاثنين على معدل التغير الزمني للقناة بالإضافة إلى التعقيد الحسابي. حيث تم اعتماد الطريقة الثانية في هذا العمل. [10]

5- النموذج المقترح:

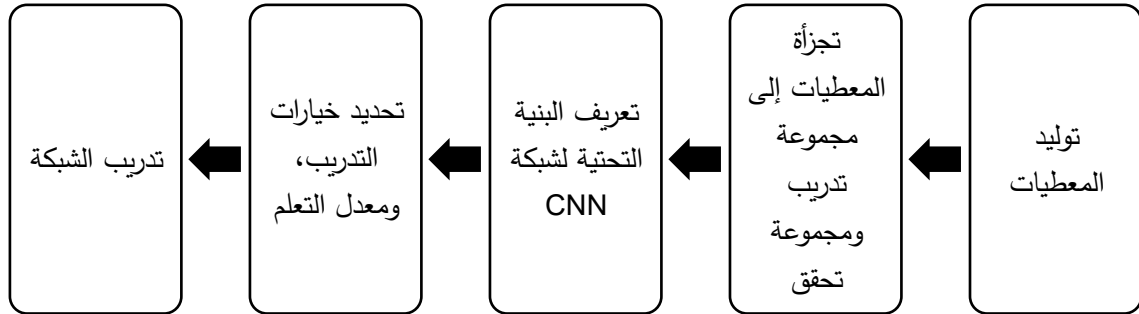
تم تصميمه باستخدام برنامج MATLAB.

فيما يلي نذكر أهم مراحل التطبيق:

نموذج تدريب الشبكة العصبونية:

الشكل (٥) يوضح المخطط الصندوقي لعملية تدريب الشبكة العصبونية على المعطيات.

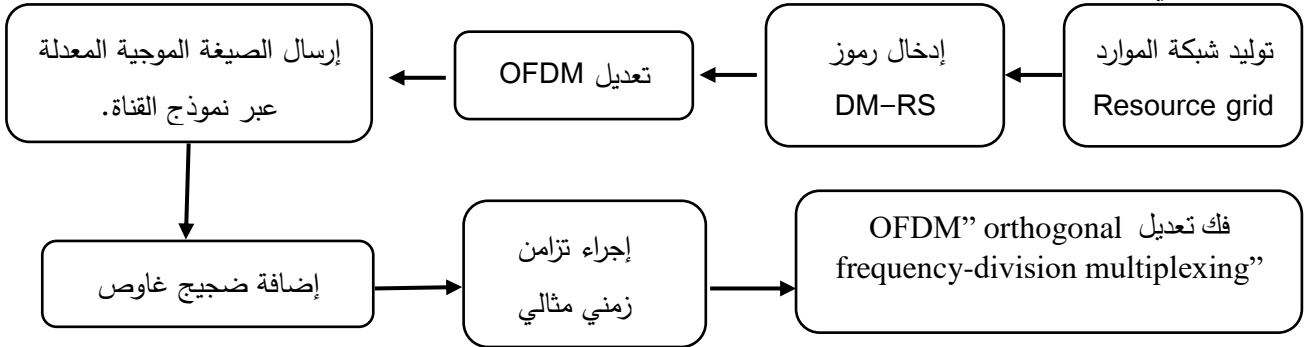
يتم في البداية توليد المعطيات المرسله عبر الشبكة، ثم تتم تجزئتها إلى مجموعتين، الأولى تستخدم لتدريب الشبكة العصبونية، والثانية هي مجموعة التحقق وتستخدم لاختبار الأداء. بعد ذلك يتم تعريق مكونات وبنية الشبكة كالتطبيقات والمرشحات، ويليهما عملية تحديد بارامترات التدريب والتعلم، ليتم بعدها بدء مرحلة تدريب الشبكة.



الشكل (٥) المخطط الصندوقي لمرحلة تدريب الشبكة العصبونية

نموذج محاكاة القناة "Physical Downlink Shared Channel" PDSCH DM-RS

إن محاكاة القناة الفيزيائية المستخدمة لإرسال الرموز المرجعية تتم عبر عدة مراحل، تبدأ بتوليد شبكة الموارد، ليتم بعدها إدخال الرموز المرجعية المرسله. يُطبق تعديل OFDM ومن ثم إرسال الصيغة الموجية عبر القناة الفيزيائية بعد إضافة ضجيج غاوص. (الكود ديناميكي حيث يمكن اختيار تقنيات تعديل وصيغ موجية مختلفة) ومن الضروري جداً تطبيق تزامن بين طرفي الاتصال لتحقيق أداء فعال وتجنب الأخطاء أو فقدان المعطيات. في طرف الاستقبال، يتم إجراء عملية فك تعديل OFDM لاستخلاص المعطيات (الرموز).



الشكل (٦) المخطط الصندوقي لنموذج محاكاة القناة

ويوضح الجدول (١) أهم البارامترات المستخدمة والقيم المقابلة لها:

الجدول (١) - البارامترات المستخدمة للمحاكاة

البارامتر	القيمة	المصطلح باللغة العربية
SNRdB	10 dB	نسبة الإشارة إلى الضجيج
channel.DelayProfile	Tapped Delay Line 'TDL-A'	نموذج القناة
channel.DelaySpread	3e-7	تأخير الانتشار
channel.MaximumDopplerShift	50	انزياح دوبلر الأعظمي
waveformInfo	OFDM	الصيغة الموجية

نماذج القناة اللاسلكية: [11]

تمّ تحديد نوعين من نماذج قنوات الانتشار من أجل محاكاة الترددات في المجال 500 MHz-100 GHz، وذلك في التقرير التقني (Technical report) TR 38.900 للهئية القياسية 3GPP ، وهما: خط التأخير الفرعي "Tapped Delay Line" TDL وخط التأخير العنقودي "Clustered Delay Line" CDL

هذه القنوات تدعم عرض نطاق للإشارة يصل إلى 2GHz.

يحدد التقرير التقني TR38.900 خمس حالات نموذجية لكل قناة وهي كالتالي:

• CDL/TDL-A, CDL/TDL-B, CDL/TDL-C وتستخدم في حالات غياب خط النظر

"Non-Line-Of-Sight" NLOS.

• CDL/TDL-D, CDL/TDL-E وتستخدم في حالات وجود خط النظر

"Line-Of-Sight" LOS.

نموذج القناة "TAPPED-DELAY-LINE" TDL-A

يصف نموذج TDL المسارات بين المرسل والمستقبل بواسطة بارامترات إحصائية، دون مراعاة هندسة البيئة. يتم تمثيل الاستجابة النبضية للقناة في المجال الزمني بعدد منفصل من الوصلات (taps) ، لكل منها معاملاتها المتغيرة مع الوقت والسعة والتأخير، كما موضح في المعادلة (1) والشكل (٧). [11]

$$h(t, \tau) = \sum_{i=1}^N c_i(t) \cdot \delta(\tau - \tau_i). \quad (1)$$


حيث:

N هو عدد المسارات الكلي.

$c_i(t)$: هو معامل المطال العقدي المستقل عن الزمن.

δ : هو تابع دلتا ديراك

τ_i : هو تأخير المسار رقم i.



الشكل (٧) آلية عمل نموذج القناة TDL

حيث يتم تمثيل كل وصلة (tap) بتابع Dirac delts، والاستجابة النبضية $h(t, \tau)$ متغيرة خلال الزمن وتُمثل بمجموع كل الوصلات ذات التأخير.

هذا النوع من نماذج القناة يفترض أن الاستجابة النبضية للقناة هي تمثيل منتهي للقناة، من خلال العدد الأعظمي للمسارات N . وتكون الدقة بين مسارين محدودة بعرض حزمة النظام، كما يلي في العلاقة (٢):

$$\delta_{\tau} = \frac{1}{W} \quad (٢)$$

حيث δ_{τ} تمثل الدقة الزمنية الأعظمية، و W هو عرض الحزمة.

الصيغة الموجية OFDM

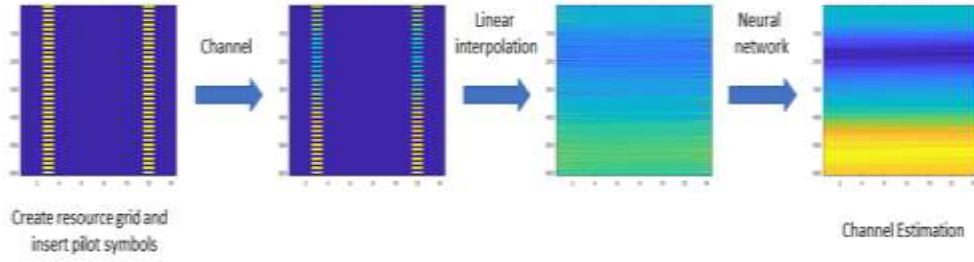
تعدد الإرسال بتقسيم التردد المتعامد أو OFDM عبارة عن نظام رقمي لنقل البيانات متعدد الموجات يتم فيه تقسيم دفق واحد من البيانات أو دفق ثنائي من البيانات بين عدة ترددات حاملة ضيقة النطاق أو ترددات حاملة فرعية متقاربة بدلاً من نقل البيانات على ناقل وحيد التردد وعبر النطاق الترددي بأكمله. ويعتبر امتداداً لتعدد الإرسال بتقسيم التردد (FDM). [12]

بدلاً من إرسال إشارة ذات معدل بيانات مرتفع على تردد موجة حاملة واحدة، يقسم OFDM الإشارة إلى عدة موجات حاملة فرعية متقاربة ويرسل جميع الموجات الحاملة الفرعية بالتوازي على نفس عرض النطاق، وبالتالي تحسين الكفاءة الطيفية. تُشكل تقنية OFDM تقنية مهمة جداً للاتصالات عريضة النطاق، مما يجعلها مثالية للتطبيقات والأنظمة الحديثة مثل الشبكات اللاسلكية والتلفزيون الرقمي وشبكات المنطقة الشخصية اللاسلكية (WPAN) وأنظمة الاتصالات المتنقلة كالجيل الرابع والجيل الخامس. [12]

4- النتائج المناقشة:

يسمح النموذج الذي تم تصميمه في هذا العمل بالمقارنة بين عدة تقنيات ومن أجل عدة حالات وعدة قيم للمحددات الأساسية، كما أنه يعطي إمكانية إظهار مخططات ومنحنيات بيانية بالإضافة للنتائج العددية للقيم المقاسة. تمت المقارنة بين القناة الفعلية، وحالة القناة العملية، وتقدير القناة باستخدام الشبكة العصبونية، وذلك لنفس نموذج القناة.

لإجراء تقدير القناة باستخدام الشبكة العصبونية، تتم معالجة وإدخال شبكة الموارد المستقبلية، حيث أن الشبكة العصبونية تعالج شبكة الموارد على أنها صورة ثنائية البعد 2D-image، بحيث يتم تقسيم الصورة إلى الأجزاء الحقيقية والتخيلية وإدخال هذه الصور معاً إلى الشبكة العصبونية كدفعة واحدة، كما هو موضح في الشكل (٧)

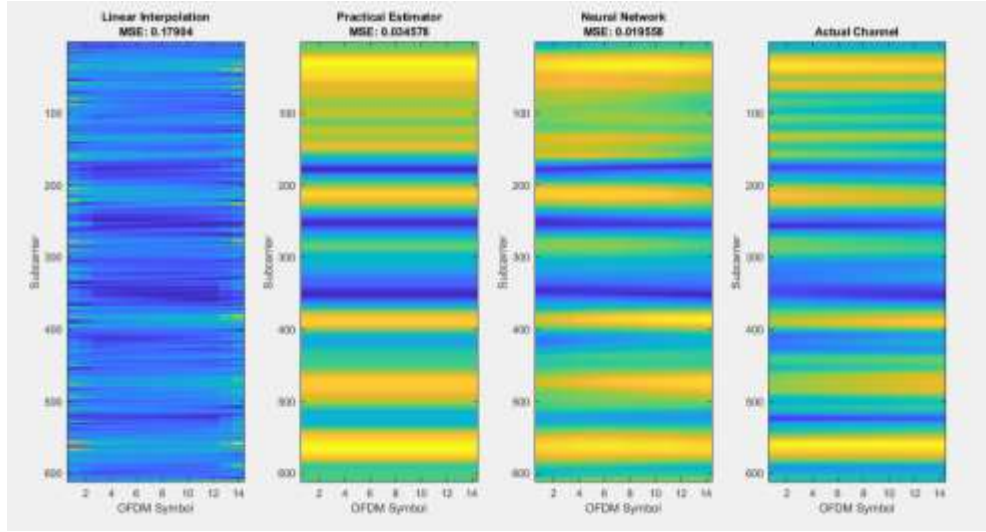


الشكل (٧) معالجة شبكة الموارد

في حالة القناة العملية، يتم استخدام مرشحات للحصول على المسار الأفضل ذو الريح الأعلى من بين المسارات المتعددة المتاحة في القناة.

عملية المقارنة تمت من خلال قياس (MSE) لكل حالة مدروسة للشبكة.

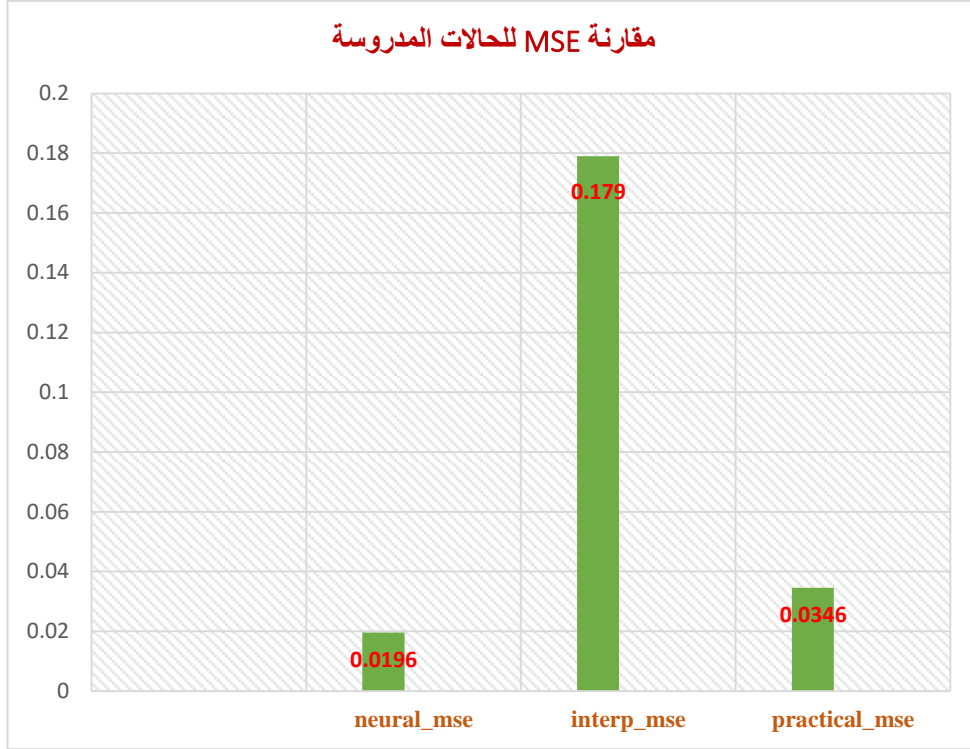
يُظهر الشكل (٨) مقارنة بين طيف رموز OFDM من أجل كل حامل فرعي لكل طريقة مدروسة مع حالة القناة الفعلية، حيث يبدو واضحاً تفوق طريقتي تقدير القناة باستخدام الشبكة العصبونية والتقدير العملي على حالة الاستيفاء الخطي، ولكن الأكثر دقة وفعالية هي حالة تقدير القناة باستخدام الشبكة العصبونية حيث نلاحظ تطابق بين رموز OFDM مع الحالة الفعلية (تطابق بين الرموز المرسل والمستقبل)، وذلك عائد لقدرتها على تعلم خصائص القناة بشكل فعال من خلال تدريبها على مجموعات المعطيات واستخدامها في تقدير وتنبؤ القيم.



الشكل (٨) مقارنة بين طيف رموز OFDM

الشكل (٩) يوضح القيم العددية لمتوسط معدل الخطأ للحالات المدروسة، حيث تؤكد القيم الناتجة على تفوق طريقة تقدير قناة الجيل الخامس باستخدام التعلّم العميق على باقي التقنيات لكونها تملك متوسط الخطأ الأقل (٠.٠١٩٦).

النتائج تبين ميزة التعلّم العميق في تقدير القناة وتقليل التعقيد وتحسين دقة الأنظمة اللاسلكية.



٥- الاستنتاجات والتوصيات

نستنتج مما سبق:

- ضرورة تقدير القناة في الأنظمة الخلوية لتجنب المشاكل والأخطاء الممكن حدوثها لأسباب كثيرة، أهمها ظاهرة المسارات المتعددة التي تعاني منها الأنظمة الخلوية، والتي تؤثر على أداء النظام ككل.
- فعالية تقنيات التعلم العميق والتعلم الآلي ودقتها العالية تجعلها خيار مناسب لتقدير قناة الجيل الخامس، ولكن اختيار التقنية أو الخوارزمية يتعلق بمتطلبات الشبكة والمستخدمين، وبنوعية الخدمات والتطبيقات التي يطلبها المستخدمون، بالإضافة إلى السيناريو والبيئة المدروسة.
- يمكن دراسة أثر تغيير الصيغة الموجية المستخدمة ونموذج القناة ونسبة الإشارة إلى الضجيج على أداء ودقة الشبكة العصبونية في تقدير القناة في نظام الجيل الخامس.

6- المراجع

- [1] Almutairi, Mubarak. (2022). *Deep Learning-Based Solutions for 5G Network and 5G-Enabled Internet of Vehicles: Advances, Meta-Data Analysis, and Future Direction*. Mathematical Problems in Engineering. 2022. 10.1155/2022/6855435.
- [2] Jung, Alexander. (2022). *Machine Learning: The Basics*. 10.1007/978-981-16-8193-6.
- [3] Gallo, Crescenzo. (2015). *Artificial Neural Networks: tutorial*.
- [4] Sarker, I.H. *Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions*. SN COMPUT. SCI. 2, 420 (2021). <https://doi.org/10.1007/s42979-021-00815-1>
- [5] Shivsharan, Nitin. (2022). *Applications of Deep Learning*.

- [6] Alzubaidi, L., Zhang, J., Humaidi, A.J. et al. *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*. J Big Data 8, 53 (2021). <https://doi.org/10.1186/s40537-021-00444-8>
- [7] Ghosh, Anirudha & Sufian, A. & Sultana, Farhana & Chakrabarti, Amlan & De, Debashis. (2020). *Fundamental Concepts of Convolutional Neural Network*. 10.1007/978-3-030-32644-9_36.
- [8] Bezdán, Tímea & Bacanin, Nebojsa. (2019). *Convolutional Neural Network Layers and Architectures*. 445-451. 10.15308/Sinteza-2019-445-451.
- [9] A. L. Ha, T. Van Chien, T. H. Nguyen, W. Choi and V. D. Nguyen, "Deep Learning-Aided 5G Channel Estimation," *2021 15th International Conference on Ubiquitous Information Management and Communication (IMCOM)*, Seoul, Korea (South), 2021, pp. 1-7, doi: 10.1109/IMCOM51814.2021.9377351.
- [10] Mohammed, A.S.M., Taman, A.I.A., Hassan, A.M. et al. *Deep Learning Channel Estimation for OFDM 5G Systems with Different Channel Models*. *Wireless Pers Commun* **128**, 2891–2912 (2023). <https://doi.org/10.1007/s11277-022-10077-6>
- [11] Zhang, Jianhua & Shafi, Mansoor & Molisch, Andreas & Tufvesson, Fredrik & Wu, Shangbin & Kitao, Koshiro. (2018). *Channel Models and Measurements for 5G*. *IEEE Communications Magazine*. 56. 12-13. 10.1109/MCOM.2018.8570033.
- [12] Khosla, Dishant & Singh, Sohni. (2018). *OFDM Modulation Technique & its Applications: A Review*. 101-105.