

## تحليل تأثير المكونات اللاخطية على تقدير حالة القناة في نظام الهوائيات الكثيف

م.عمار زريقة\*

(الإيداع: 24 آذار 2021 ، القبول: 23 آيار 2021 )

الملخص:

معرفة حالة القناة CSI channel state information من أهم القضايا في نظم الهوائيات متعددة المداخل والمخارج الكثيف Massive MIMO ، وخاصة في حالة تعدد المستخدمين في النظام حيث يصبح التقدير الدقيق لحالة القناة ركيزة أساسية للأداء الجيد. يلج المستخدمون إلى الشبكة عبر الوصلة الصاعدة uplink وترسل المحطة القاعدية بياناتها إلى المستخدم عبر الوصلة الهابطة. downlink تقدر حالة القناة عادة على الوصلة الصاعدة بسبب تفوق المحطة القاعدية في القدرة الحسابية على طرفية المستخدم. user equipment UE. تم استخدام تقنية التعلم العميق لتقدير حالة القناة على الوصلة الهابطة بافتراض عدة نماذج لا خطية في الواجهات الراديوية وتحليل أدائها ومقارنتها مع النموذج الخطي. تؤكد النتائج الرقمية جدارة الحل المقترح، وتظهر أنه يمكن الحصول على أداء فعال مقارنة بالحلول التقليدية المعروفة التي تفترض سلوك خطي لمكونات القناة، أو الطرق التي تعتمد على الترتيبات الصغرى.

الكلمات المفتاحية: أنظمة الهوائيات المتعددة، تقدير حالة القناة ، الشبكات العصبونية العميقة.

\* حاصل على شهادة الماجستير في هندسة الاتصالات والالكترونيات جامعة تشرين

## Analysis the effect of nonlinear components on estimating channel in Massive MIMO system

Eng.Ammar Zreka\*

(Received: 24 March 2021, Accepted: 23 April 2021)

### Abstract:

Accurate knowledge of channel state information (CSI) is one of the main challenges in Massive MIMO, especially in the case of multiple users in the system, where accurate estimation of channel state becomes a fundamental pillar of good performance.

Users log in to the base station via the uplink and the base station sends its data to the user via the downlink. The channel state is usually estimated at the uplink due to the computational superiority of the base station over the user equipment UE.

Deep learning technique was used to estimate the state of the channel on the downlink assuming several nonlinear models in the radio interfaces and analyze their performance and compare them with the linear model

The numerical results confirm the merit of the proposed solution, and show that effective performance can be obtained compared to well-known conventional solutions that assume linear behavior of channel components, or methods that rely on least squares.

**Key words:** multiple antenna systems, channel state estimation, deep neural networks

---

\*Master in communication and electronic engineering in Tishren University

## 1-المقدمة:

تعتبر أنظمة الهوائيات متعددة المداخل والمخارج الكثيف Massive MIMO المكون الرئيسي للطبقة الفيزيائية في شبكات الاتصالات الحديثة 5G والشبكات اللاسلكية عريضة الحزمة الترددية [6] [2] [4]. تعتمد هذه الأنظمة على توظيف عدد كبير من الهوائيات في المحطة القاعدية وتهدف إلى خدمة عدد من أجهزة المستخدمين UE في الوقت نفسه عن طريق تحسين الفعالية الطيفية في شبكات الاتصال الخلوية [3] [6][4].

توفر تقنية MIMO عدة أنواع من الأرباح كريح التنوع diversity gain وريح التنضيد multiplexing gain. تتطلب الاستفادة من الأرباح التي توفرها تقنية MIMO معرفة دقيقة لحالة القناة بين المحطة القاعدية والمستخدم واستخدام هذه الحالة لترميز الإشارات المرسل على الوصلة الهابطة بشكل مسبق للوصول إلى أداء أمثلي. يمكن زيادة كفاءة أنظمة الازدواجية بالتقسيم الزمني [4] عبر تقدير حالة القناة على الوصلة الصاعدة بواسطة إشارات إرشادية متعامدة تُرسل من المستخدم إلى المحطة القاعدية، ثم استغلال عكسية القناة لتقدير حالة القناة على الوصلة الهابطة بالاستفادة من التقدير على الوصلة الصاعدة.

من الناحية العملية لا يمكن اعتبار حالة القناة القاعدية بين المرسل والمستقبل عكوسة حتى في حالة ازدواجية بالتقسيم الزمني بسبب احتواء الواجهات الراديوية على عناصر غير خطية. لذلك، لا بد من تقويم اللاخطية التي تفرضها الواجهات الراديوية إذا أردنا الاستفادة من تقدير حالة القناة على الوصلة الصاعدة لتقدير حالتها على الوصلة الهابطة. تسمى عملية التقويم هذه معايرة القناة وتتكون من مرحلتين:

- تقدير معاملات المعايرة بين الوصلة الهابطة والوصلة الصاعدة.
- تطبيق معاملات المعايرة على الوصلة الصاعدة للحصول على تقدير الوصلة الهابطة.

في الآونة الأخيرة، تم استخدام تقنيات التعلم العميق في مجال الاتصالات وتحديدًا في فك ترميز الإشارات المرسل كما في [10][8][7]. تقترح الدراسة في [8] تدريب مفكك ترميز decoder باستخدام أدوات التعلم العميق لفك ترميز الإشارات المرسل. يعتبر استخدام تقنيات التعلم العميق في تقدير حالة القناة جديدًا نسبيًا. في هذا البحث، سنقيم طريقة عمل شبكة عصبونية عميقة لتقدير حالة القنوات بين الوصلة الصاعدة والوصلة الهابطة في نظام الهوائيات متعدد المداخل والمخارج والكثيف Massive MIMO. يتضمن العمل تدريب شبكة عصبونية عميقة DNN لتقريب العلاقة اللاخطية المحتملة التي تربط بين حالة القناة على الوصلة الصاعدة وحالة القناة على الوصلة الهابطة. مستخدمين أنماط لاخطية جديدة غير مدروسة سابقًا لتقييم أداء تقنية التعلم العميق. يتم تدريب الشبكة العصبونية في طور التدريب من قياسات حالة القناة على الوصلة الهابطة والوصلة الصاعدة ثم يتم استخدام الشبكة العصبونية لمعايرة قنوات جديدة كلياً.

## 2-أهداف البحث وأهميته:

تفرض الواجهات الراديوية علاقة لاخطية بين حالة القناة على الوصلة الصاعدة وحالتها على الوصلة الهابطة في أنظمة الاتصالات متعددة الهوائيات MIMO. تزيد اللاخطية من صعوبة الاعتماد على حالة القناة في الوصلة الصاعدة لتقدير حالتها في الوصلة الهابطة، لأن العلاقة اللاخطية تجعل القناة غير عكوسة حتى في حالة الأنظمة التي تعتمد الازدواجية بالتقسيم الزمني TDD. يهدف هذا البحث لتقييم استخدام تقنيات التعلم العميق في معايرة القناة بين الوصلة

الصاعدة والوصلة الهابطة من حيث تأثيرها على أداء نظام اتصالات الهوائيات متعدد المداخل والمخارج الكثيف Massive MIMO بافتراض أنماط جديدة من التوابع اللاخطية غير مدروسة في الدراسات المرجعية ، وذلك بحساب متوسط الخطأ التربيعي في التقدير، معدل الخطأ في البت بدلالة SNR بالإضافة إلى تأثير استخدام هذه التقنية مع الأنماط اللاخطية على سعة النظام.

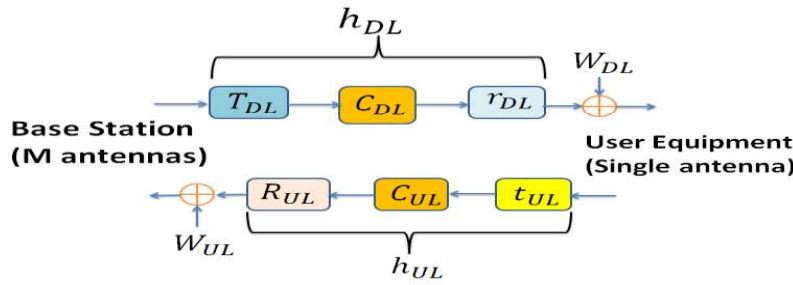
### 3- طرائق البحث ومواده:

#### 1- نموذج النظام

في أنظمة الاتصالات العملية، تكون الوصلة الهابطة والوصلة الصاعدة في الحزمة القاعدية بين أي زوج من العقد غير خطية بسبب المكونات اللاخطية للواجهات الراديوية كمكبرات الإشارة والتي تصنف كأجهزة عديمة الذاكرة Memoryless تظهر لاخطيتها عندما تزيد استطاعة إشارة الدخل وتقترب من عتبة الاشباع [9] .

نفترض نظام ثنائي الاتجاه يتكون من محطة قاعدية ذات  $M$  هوائي وطرفية مستخدم بهوائي وحيد كما هو موضح في الشكل (1)). يمثل الجزء العلوي من الشكل الوصلة الهابطة من المحطة القاعدية إلى جهاز المستخدم بينما يوضح الجزء السفلي

الوصلة الصاعدة من جهاز المستخدم إلى المحطة القاعدية. تمثل المصفوفات العقدية  $T_{DL}$  و  $R_{UL}$  ذات الأبعاد  $M \times M$  استجابة الواجهة الراديوية للمحطة القاعدية في طور الإرسال والاستقبال على الترتيب.



تمثل العناصر القطرية في المصفوفات السابقة التأثيرات الخطية المنسوبة إلى التأثيرات المتبادلة بين أجزاء الواجهة الراديوية للإرسال مع أجزاء الواجهة الراديوية للاستقبال بينما تمثل العناصر غير القطرية الترابط المتبادل بين الهوائيات. يمثل الشعاعين  $C_{DL} \in \mathbb{C}^{1 \times M}$  و  $C_{UL} \in \mathbb{C}^{M \times 1}$  قنوات الانتشار اللاسلكية عبر الهواء OTA over the air للوصلة الهابطة والوصلة الصاعدة على الترتيب. نفترض خلال هذا البحث قنوات مسطحة تردديا كالمستخدمة في

أنظمة الاتصالات ذات الحزمة الضيقة أو في الحامل الجزئي من الأنظمة التي تستخدم تقنية OFDMA.

يشير الشعاعين  $h_{DL} \in \mathbb{C}^{1 \times M}$  و  $h_{UL} \in \mathbb{C}^{M \times 1}$  إلى حالة القناة في الوصلة الهابطة والوصلة الصاعدة على الترتيب في الحزمة القاعدية الرقمية. أخيرا يشير الشعاع  $W_{UL} \in \mathbb{C}^{M \times 1}$  إلى شعاع الضجيج الأبيض الغاوسي AWGN المضاف في المحطة القاعدية، بينما يشير الرمز العقدي  $W_{DL}$  إلى الضجيج الأبيض الغاوسي المضاف عند طرفية المستخدم UE.

نفترض أن عدد  $N$  من أجهزة المستخدمين ترسل بشكل متزامن عينات إرشادية عبر الوصلة الصاعدة إلى المحطة القاعدية ذات  $M$  هوائي. نجمع كل العينات الإرشادية بشعاع واحد على الشكل التالي:

$$X_{UL} \triangleq \left[ x_{UL}^{(1)} \ x_{UL}^{(2)} \ x_{UL}^{(3)} \ \dots \ x_{UL}^{(N)} \right]^T \quad \text{with } n = 1, 2, \dots, N \quad (1)$$

حيث  $x_{UL}^{(N)}$  تمثل العينة الإرشادية للمستخدم رقم  $n$ .

الإشارات العقدية المؤلفة من  $M$  إشارة والمستقبل في المحطة القاعدية بواسطة  $M$  هوائي يمكن أن يعبر عنها بالعلاقة التالية:

$$y_{UL} = f(H_{UL}, x_{UL}) + w_{UL} \quad (2)$$

بحيث:

$$H_{UL} \triangleq \left[ h_{UL}^{(1)} \ h_{UL}^{(2)} \ h_{UL}^{(3)} \ \dots \ h_{UL}^{(N)} \right] \in C^{M \times N}$$

$$h_{UL}^{(n)} \triangleq \left[ h_{UL}^{(1,n)} \ h_{UL}^{(2,n)} \ h_{UL}^{(3,n)} \ \dots \ h_{UL}^{(M,n)} \right]^T \in C^{M \times 1}$$

يمثل  $h_{UL}^{(n)}$  القناة بين المحطة القاعدية والمستخدم رقم  $n$ ، و  $f(\cdot)$  الشكل العام للتابع اللاخطي لـ  $H_{UL}$  و  $x_{UL}$ . عندما يكون تقدير قناة الوصلة الهابطة هو الهدف تقوم المحطة القاعدية بإرسال شعاع العينات الإرشادية بشكل متتابع إلى كل هوائي من هوائيات أجهزة المستخدمين وعددهم يساوي إلى  $N$ . يمثل الشعاع التالي شعاع العينات الإرشادية:

$$X_{DL} \triangleq \left[ x_{DL}^{(1)} \ x_{DL}^{(2)} \ x_{DL}^{(3)} \ \dots \ x_{DL}^{(N)} \right]^T$$

يمثل  $x_{DL}^{(m)}$  العينة الإرشادية المرسل من الهوائي رقم  $m$  في المحطة القاعدية.

يعطى شعاع القيم العقدية المستقبلية عند كل المستخدمين بالعلاقة:

$$y_{DL} = g(H_{DL}, x_{DL}) + W_{DL} \quad (3)$$

بحيث

$$H_{DL} \triangleq \left[ h_{DL}^{(1)} ; h_{DL}^{(2)} ; h_{DL}^{(3)} ; \dots ; h_{DL}^{(N)} \right] \in C^{N \times M}$$

$g(\cdot)$  الشكل العام للتابع اللاخطي الذي يربط بين الحزمة القاعدية للوصلة الهابطة مع الحزمة القاعدية للوصلة الصاعدة. يمثل الشعاع  $W_{DL}$  الضجيج الأبيض الغاوسي المضاف إلى كل أجهزة المستخدمين ( $N$  جهاز).

$$W_{DL} \triangleq \left[ w_{DL}^{(1)} \ w_{DL}^{(2)} \ w_{DL}^{(3)} \ \dots \ w_{DL}^{(N)} \right] \in C^{N \times 1}$$

تعطى علاقة الإشارات المستقبلية في المحطة القاعدية على الوصلة الصاعدة، والإشارات المستقبلية في طرفيات المستخدمين على الوصلة الهابطة -بافتراض قناة مسطحة تردديا- بالعلاقات التالية [3]:

$$y_{UL} = H_{UL} x_{UL} + w_{UL} \quad (4)$$

$$y_{DL} = H_{DL} x_{DL} + w_{DL} \quad (5)$$

بالاستناد إلى أن نظام الـ MIMO يعمل بنمط TDD، تكون عكسية القناة لكل وصلة بين المحطة القاعدية وطرفية المستخدم رقم  $n$  محفوظة. أي أن:

$$c_{UL}^{(n)} = \left( c_{DL}^{(n)} \right)^T$$

في هذه الحالة تعطى حالة قنوات الحزمة القاعدية لكل من الوصلة الصاعدة والوصلة الهابطة من أجل كل ارتباط  $n$  بالعلاقة:

$$h_{DL} = r_{DL}^{(n)} c_{DL}^{(n)} T_{DL}^{(n)} \quad (6)$$

$$h_{UL} = R_{UL}^{(n)} \left( c_{DL}^{(n)} \right)^T t_{UL}^{(n)} \quad (7)$$

وبالتالي يمكن إيجاد علاقة بين حالة القناة القاعدية على الوصلة الصاعدة والوصلة الهابطة على النحو التالي:

$$\begin{aligned} h_{DL}^{(n)} &= r_{DL}^{(n)} c_{DL}^{(n)} T_{DL}^{(n)} \\ h_{DL}^{(n)} &= r_{DL}^{(n)} \left( (R_{UL}^{(n)})^{-1} h_{UL}^{(n)} (t_{UL}^{(n)})^{-1} \right)^T T_{DL}^{(n)} \\ h_{DL}^{(n)} &= \underbrace{r_{DL}^{(n)} \left( t_{UL}^{(n)} \right)^{-1}}_{\triangleq a^{(n)}} \left( h_{UL}^{(n)} \right)^T \underbrace{\left( (R_{UL}^{(n)}) \right)^{-T}}_{\triangleq B^{(n)}} T_{DL}^{(n)} \\ h_{DL}^{(n)} &= a^{(n)} \left( h_{UL}^{(n)} \right)^T B^{(n)} \end{aligned} \quad (8)$$

تمر عملية معايرة قناة لاسلكية عكوسة عبر الهواء over the air OTA لنظام كثيف متعدد المداخل متعدد المخارج MIMO يستخدم نمط الازدواجية بالتقسيم الزمني TDD بمرحلتين [9]:

1. في الطور الأول يتم اجراء عملية المعايرة التي تتضمن تقدير القيم العقدية  $a^{(n)}$  و  $B^{(n)} \in \mathbb{C}^{M \times M}$  المبينة في العلاقة (7) من أجل جميع قيم  $n$ .
2. خلال الطور الثاني يتم استخدام المصفوفات المقدرة في الطور الأول مع حالة القناة القاعدية المقاسة على الوصلة الصاعدة  $\forall n$  ، لتقدير حالة القناة القاعدية على الوصلة الهابطة  $\forall n$  ،  $h_{DL}^{(n)}$  بالاعتماد على العلاقة (7).

## 2- معايرة القناة باستخدام الشبكة العصبونية العميقة DNN

تتألف العملية من طور تدريب للحصول على معاملات الشبكة العصبونية المصممة، ثم طور معايرة القناة، ويتم فيها تمرير حالة القناة القاعدية على الوصلة الصاعدة إلى دخل الشبكة العصبونية التي تم تدريبها في الطور الأول لنحصل على تقدير لحالة القناة القاعدية على الوصلة الهابطة.

- الشبكة العصبونية العميقة لمعايرة نظام هوائيات متعددة المداخل والمخارج الكثيف **Massive MIMO**:

يمكن للشبكة العصبونية ذات التغذية الأمامية المؤلفة من طبقة مخفية واحدة متصلة بالكامل fully-connected أن تقرب توابع مستمرة معرفة على المجموعة  $R^{N \times 1}$ . تستطيع شبكة عصبونية قياسية مكونة من عدة طبقات مخفية تقرب أي تابع مستمر إلى أي درجة مرغوبة من الدقة.

تتألف هذه الشبكة العصبونية من خمس طبقات كالتالي [3]:

- طبقة الدخل.
- ثلاث طبقات مخفية.
- طبقة الخرج.

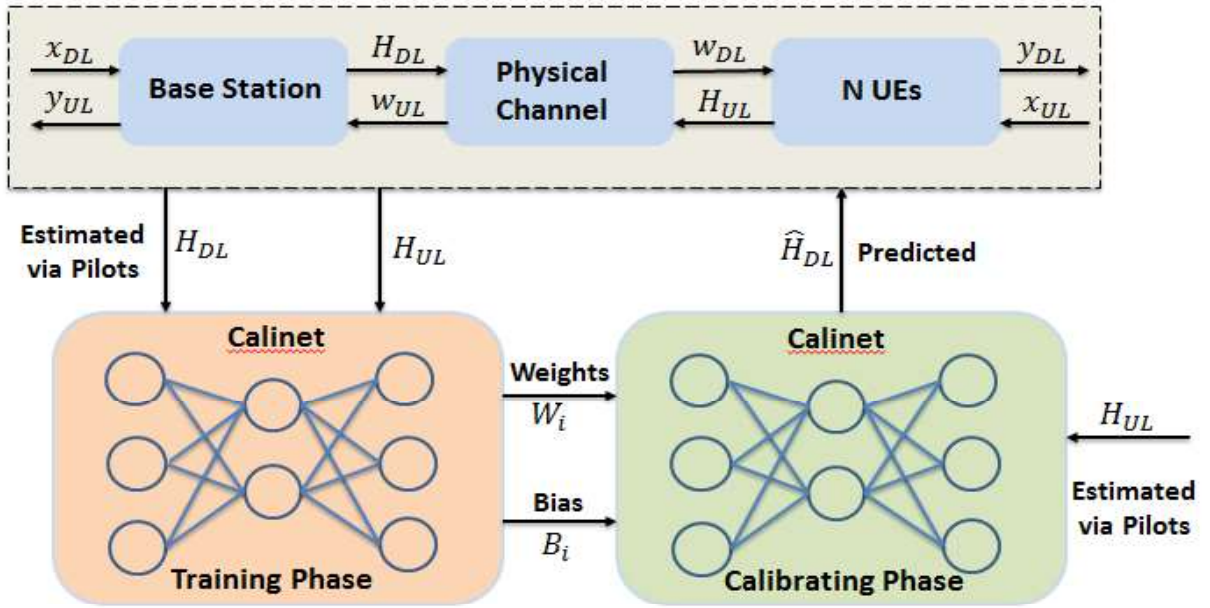
يوجد العديد من الخلايا العصبونية في كل طبقة مخفية، يكون خرج كل طبقة عبارة عن تابع غير خطي لمجموع القيم الموزونة للخلايا العصبونية عند دخل هذه الطبقة تتألف طبقة دخل الشبكة العصبونية من  $M \times N$  من الخلايا العصبونية التي ترسل معاملات القناة  $H_{UL}$  إلى أول طبقة مخفية  $l_1$ . يتمثل دور الطبقات المخفية وطبقات الخرج بإيجاد

العلاقة بين  $H_{DL}$  و  $H_{UL}$ . استخدمنا التابع  $\tanh(\cdot)$  كتابع تنشيط  $\sigma(\cdot)$  في كل الطبقات، لأنه يعطي نتائج جيدة في تقريب

التتابع غير الخطية ويؤمن تطابق تام في المجال  $[-1,1]$

تخضع الشبكة العصبونية بداية لطور تدريب، بعد ذلك تستخدم الشبكة العصبونية المدربة لمعايرة القناة. تكون المرحلتين بشكل مفصل على الشكل التالي:

1. طور التدريب: في هذا الطور تستخدم العينات الارشادية في كل من الوصلة الهابطة والوصلة الصاعدة وفي كلا الاتجاهين للحصول على  $P$  زوج من تقديرات القناة ثنائية الاتجاه. لنفرض:  $(H_{DL,p}, H_{UL,p})$  تعطي الزوج  $p$  من تقديرات الوصلة الهابطة والوصلة الصاعدة مع  $p = 1, 2, \dots, P$ . ثم مجموعة العناصر المدربة



الشكل رقم (2): تمثيل مراحل عملية المعايرة

$P$  تغذي الشبكة العصبونية وتُنشر خوارزمية التدريب لضبط معاملات الشبكة العصبونية في  $\theta$ . هذه العملية مفصلة في القسم الفرعي التالي.

2. طور معايرة القناة: الشبكة العصبونية المدربة من الطور السابق تُستخدم للتنبؤ بالوصلة الهابطة انطلاقاً من تقديرات الوصلة الصاعدة. نحصل على تقدير الوصلة الصاعدة  $H_{UL}$  من العينات الارشادية للوصلة الصاعدة والتي تغذي الشبكة العصبونية وبالتالي نحصل على الوصلة الهابطة المتوقعة. نشير إلى تلك القنوات بالشكل التالي:

$$\hat{H}_{DL} \triangleq [\hat{h}_{DL}^{(1)}; \hat{h}_{DL}^{(2)}; \dots; \hat{h}_{DL}^{(N)}] \in C^{N \times M}$$

- عملية تدريب الشبكة العصبونية

في بداية طور التدريب، نحصل على عينات التدريب المطلوبة  $\{H_{UL,p}\}_{p=1}^P$  و  $\{H_{DL,p}\}_{p=1}^P$  للشبكة العصبونية عبر إرسال عينات ارشادية بين المحطة القاعدية والمستخدم. بعد ذلك، تستخدم عينات التدريب لحساب معاملات الشبكة

العصبونية من أجل تقليل الحد الأدنى لمتوسط الخطأ التربيعي MMSE بين عدد P من مخرجات الشبكة العصبونية  $\{\hat{H}_{DL,p}\}_{p=1}^P$  وعدد P من المخرجات المطلوبة  $\{H_{DL,p}\}_{p=1}^P$  أي:

$$\mathcal{L}(\hat{H}_{DL,p}(\theta), H_{DL,p}) = \sum_{p=1}^P \|\text{vec}(\hat{H}_{DL,p}(\theta)) - \text{vec}(H_{DL,p})\|^2 \quad (9)$$

حيث:  $\theta \triangleq \{\theta_1, \theta_2, \dots, \theta_5\}$  with  $\theta_l = \{W_l, b_l\}$

يشير  $\hat{H}_{DL,p}(\theta)$  إلى أن شعاع خرج الشبكة العصبونية الفعلي هو تابع لمعاملات الشبكة  $\theta$  وشعاع دخلها  $H_{UL,p}$ . من أجل تقليل الحد الأدنى لمتوسط الخطأ التربيعي بالنسبة إلى  $\theta$  يمكن استخدام العديد من خوارزميات التدريب الجاهزة التي تعتمد التغيير في تابع التدرج gradient العشوائي حيث يتم تقدير تدرج تابع الكلفة باستخدام مجموعة عشوائية من عينات التدريب.

بالتالي، في كل تكرار متتالي يتم تحديث معاملات الشبكة العصبونية بالشكل:

$$\theta_i = \theta_i - \eta \hat{\nabla} \mathcal{L}(\theta_{i-1}) \quad (10)$$

حيث يعطي  $\hat{\nabla} \mathcal{L}(\theta_{i-1})$  التدرج المقدر و  $\eta$  معدل تعلم الخوارزمية.

#### 4- النتائج والمناقشة:

قمنا في هذا البحث باستخدام الشبكة العصبونية لمعايرة العلاقة اللاخطية بين حالة القناة على الوصلة الصاعدة وحالتها على الوصلة الهابطة، قمنا بإضافة علاقات لاخطية لحالة الوصلة الهابطة والوصلة الصاعدة بين المحطة القاعدية وطرفية المستخدم كالنمط الأسّي والنمط التربيعي إضافة للعلاقات المدروسة سابقاً وبالتالي العلاقة تأخذ أحد الأشكال: 1- النمط الخطي: وتعطى علاقة الوصلة الهابطة:

$$h_{DL}^{(n)} = c^{(n)} (h_{UL}^{(n)})^T D \quad (11)$$

2- النمط اللاخطي وهي:

-تابع الظل الزائدي:

$$h_{DL}^{(n)} = c^{(n)} \tanh(h_{UL}^{(n)}) D \quad (12)$$

-التابع الأسّي:

$$h_{DL}^{(n)} = c^{(n)} \exp(h_{UL}^{(n)}) D \quad (13)$$

-التابع التربيعي

$$h_{DL}^{(n)} = c^{(n)} (h_{UL}^{(n)})^2 D \quad (14)$$


حيث  $c^{(n)}$  توزيع عقدي قياسي على شكل  $\mathcal{CN}(0,1)$  و  $D \in \mathcal{C}^{M \times M}$  عبارة عن مصفوفة واحدة.

اعتمدنا في تقييم أداء استخدام الشبكة العصبونية العميقة على حساب متوسط الخطأ التربيعي MMSE كنسبة استطاعة الإشارة إلى استطاعة الضجيج SNR. كما قمنا بتقييم أداء النظام من ناحية معدل الخطأ في البت بدلالة استطاعة الإشارة إلى استطاعة الضجيج، وقمنا بدراسة تأثير استخدام التعلم العميق (تكرار عملية التدريب مرات كثيرة وطبقات عصبونية عديدة) لتقدير حالة القناة على سعة النظام.



## 1- إعدادات النموذج المستخدم في المحاكاة:

لتصميم الشبكة العصبونية استخدمنا بيئة عمل Matlab حيث يوفر أداة جيدة للتعامل مع الشبكات العصبونية وهي Neural Network Tool Box، فكانت الشبكة العصبونية موضحة في الشكل 3. نلاحظ في الشكل أن الشبكة تتألف من طبقة دخل input layer وثلاث طبقات مخفية hidden layers وطبقة خرج output [5] [10] layer.



الشكل (3) الشبكة العصبونية المستخدمة لتقدير حالة القناة على الوصلة الهابطة

في طبقة الدخل وطبقة الخرج يساوي عدد العصبونات إلى 128 عصبونا وذلك لأن عدد هوائيات المحطة القاعدية يساوي إلى 32 هوائي، وعدد المستخدمين يساوي إلى 4 مستخدمين بالتالي يكون عدد عناصر مصفوفة القناة من أجل كل من الوصلة الهابطة والوصلة الصاعدة يساوي إلى 128. غيرنا عدد العصبونات في الطبقات المخفية فوجدنا أن عدد عصبونات يساوي إلى 32 عصبونا كاف لأداء جيد.

لتدريب الشبكة العصبونية قمنا بتقدير حالة القناة على كل من الوصلة الهابطة والصاعدة باستخدام إشارات دليلية Pilots. جمعنا ما يقارب 500 ثنائية ( $H_{UL}, H_{DL}$ ) لتدريب الشبكة العصبونية.


## 2- النتائج

### 2-1- تدريب الشبكة العصبونية


بتدريب الشبكة العصبونية حصلنا على النتائج في الأشكال التالية في كل سيناريو من السيناريوهات المفترضة. توضح هذه النتائج انخفاض متوسط الخطأ التربيعي مع تقدم عملية التدريب. ويلاحظ من الشكل 4 أن عملية التدريب في السيناريو الخطي تطلبت حوالي 200 دورة على عينات التدريب Epochs حتى تقارب الحل ووصل متوسط الخطأ التربيعي إلى مستوى  $10^{-4}$  ثم استقر الحل عند هذا المستوى. في الشكل رقم 5، تطلبت عملية التدريب في السيناريو اللاخطي من النمط tanh حوالي 300 دورة على عينات التدريب Epochs لتقارب الحل والوصول إلى مستوى  $10^{-6}$  لمتوسط الخطأ التربيعي. أما في حالة السيناريو اللاخطي من النمط التربيعي فيوضح الشكل 6 أن عملية التدريب تطلبت حوالي 90 دورة على عينات التدريب للوصول إلى مستوى  $10^{-3}$ . نلاحظ أن عملية التدريب في النمط اللاخطي الأسّي تطلبت حوالي 60 دورة على عينات التدريب للوصول إلى مستوى  $10^{-4}$ .

### التفسير:


نلاحظ أنه كلما زادت عدد دورات التدريب كلما قل الخطأ للوصول إلى حد معين من MSE وهذا يعتمد على عدة عوامل من بينها التابع المستخدم سواء كان خطياً أو لاقطياً من عدة أنواع، قمنا بتدريب الشبكة على عدة أنماط وبعدها دورات مختلف للوصول إلى قيم MSE مختلفة كما ذكرنا أعلاه.




الشكل رقم (4): علاقة متوسط الخطأ التربيعي مع تقدم عملية التدريب



الشكل رقم (5): حالة السيناريو اللاخطي من النمط tanh



الشكل رقم (6): حالة السيناريو اللاخطي من النمط التربيعي

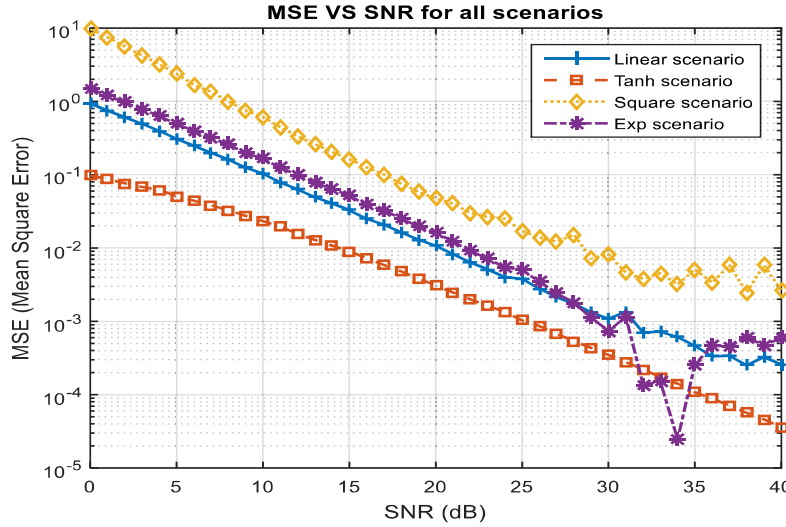


الشكل رقم (7): تناقص متوسط الخطأ التربيعي مع تقدم عملية التدريب في حالة السيناريو اللاخطي من النمط الأسّي

## 2-2- أداء الشبكة العصبونية المدربة في تقدير حالة القناة على الوصلة الهابطة

بعد عملية التدريب، يمكن استخدام الشبكة العصبونية لتقدير حالة القناة على الوصلة الهابطة بالاعتماد على حالتها في الوصلة الصاعدة. قمنا بتغيير نسبة استطاعة الإشارة إلى استطاعة الضجيج SNR بين 0-40 d B وقسنا مقدار متوسط الخطأ التربيعي لتقدير القناة على الوصلة الهابطة في كل سيناريو مفترض فحصلنا على النتائج التالية: نلاحظ من الشكل رقم أن أداء الشبكة في تقدير حالة القناة على الوصلة الهابطة بالاعتماد على حالتها في الوصلة الصاعدة ليس أفضل ما يمكن في الحالة الخطية وإنما في الحالة اللاخطية من النمط  $\tanh$ . كما نلاحظ أن أداءها أسوأ ما يمكن في حالة السيناريو اللاخطي من النمط التربيعي ومع ذلك يصل متوسط الخطأ التربيعي إلى مستوى  $10^{-2}$  من أجل SNR=20 dB.

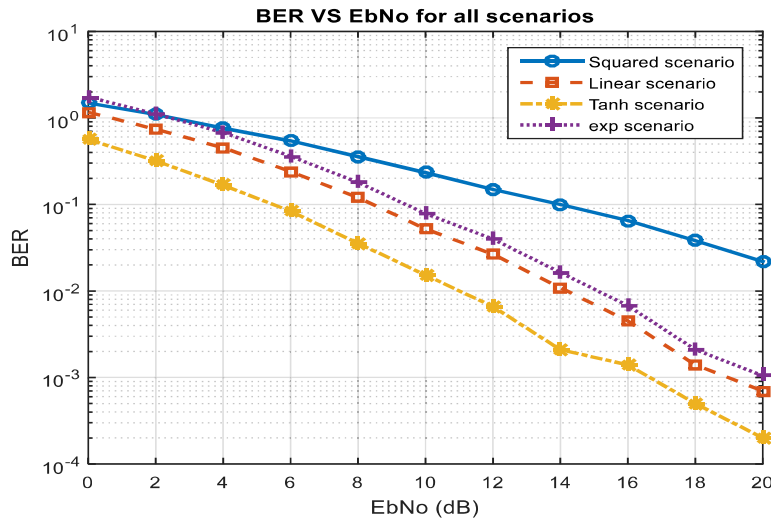
**ملاحظة:** النمط الخطي المدروس في هذه المقالة دراسة مرجعية سابقة [6] تمت مقارنة نتائجنا بالنسبة له وتم توضيح ذلك بالأشكال المبينة (8,9).



الشكل رقم (8): متوسط الخطأ التربيعي في جميع السيناريوهات المفترضة

### 2-3- أداء النظام من ناحية معدل الخطأ في البت بدلالة $E_b/N_0$

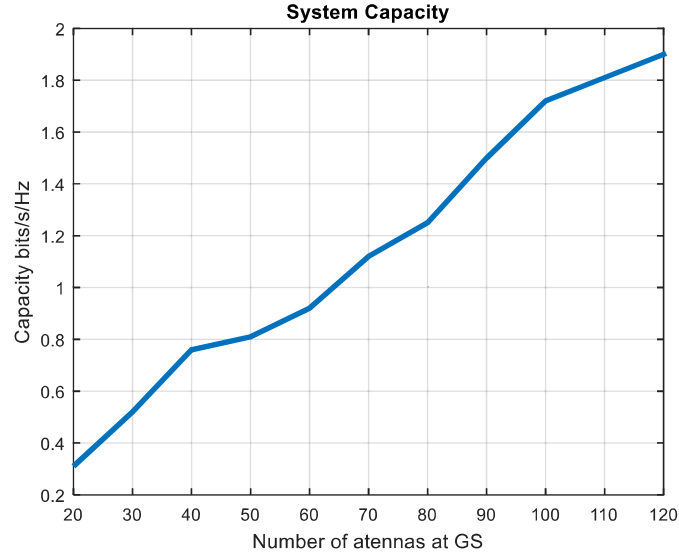
بعد قياس مقدار متوسط الخطأ التربيعي بدلالة SNR، قمنا بمحاكاة نظام اتصالات مكون من محطة قاعدية BS تحوي مصفوفة هوائيات مكونة من 32 هوائي إرسال ومستقبل وحيد الهوائي. يعدل المرسل البيانات باستخدام تعديل Bpsk ويقوم بإرسالها عبر القناة. يستخدم المستقبل حالة القناة على الوصلة الهابطة والتي تم تقديرها من حالتها على الوصلة الصاعدة باستخدام الشبكة العصبونية التي تم تدريبها واختبارها. يتم مقارنة البيانات المستقبلية مع البيانات المرسلية للحصول على قيمة BER بدلالة  $E_b/N_0$  وفق الشكل التالي:



الشكل رقم (9): BER بدلالة  $E_b/N_0$  للسيناريوهات المفترضة

نلاحظ من الشكل 9 أن تقنية التعلم العميق قد قدمت أداء جيد في تقدير حالة القناة اعتماداً على معدل خطأ البت في عدة أنماط لاختبية، ونلاحظ أنه في حالة النمط اللاخطي من نوع الظل الزائدي أن معدل خطأ بت يصل إلى  $10^{-4}$

عند قيمة  $E_b/N_0=20\text{db}$  ونلاحظ أن أداء التقنية متقارب جداً في حالتي النمط الخطي والنمط الأسّي مما يثبت أداء التقنية الجيد على اعتبار علاقة لاخطية بين حالة القناة الصاعدة والهابطة.  
 2-4- أداء النظام من ناحية السعة بدلالة عدد الهوائيات في المحطة القاعدية



الشكل رقم (9): عدد الهوائيات في المحطة القاعدية وذلك من أجل السيناريو اللاخطي من النمط EXP وعدد

مستخدمين يساوي إلى 20

قمنا بحساب الحدود الدنيا لسعة القناة (عدد البتات التي تنقل بشكل سليم وموثوق و كلما زاد عدد الهوائيات كلما قل الخطأ وبالتالي زادت السعة وتعطى بعلاقة شانون  $C = B \log_2 \left( 1 + \frac{S}{N} \right)$  حيث  $B$  عرض الحزمة الترددية ) على الوصلة الهابطة بدلالة عدد الهوائيات في المحطة القاعدية من أجل نسبة استطاعة إشارة إلى ضجيج SNR تساوي إلى 30 dB، وعدد مستخدمين يساوي إلى 20 مستخدم، فكانت النتائج كما هو واضح في الشكل 10. نلاحظ أن سعة القناة لم تتأثر بشكل كبير مع تقدير حالة القناة على الوصلة الهابطة انطلاقاً من حالة القناة على الوصلة الصاعدة بافتراض حالة لاخطية من النمط الأسّي وهذا ما يؤكد جدارة الحل (استخدام التعلم العميق لتقدير حالة القناة) 5-الاستنتاجات والتوصيات:

تناول هذا البحث طريقة قائمة على التعلم العميق لمعايرة قناة نظام هوائيات متعدد المداخل متعدد المخارج الكثيف **Massive MIMO**. على خلاف الطرق التقليدية التي تفترض وجود علاقة خطية بين قنوات الوصلات الهابطة والوصلات الصاعدة، تستطيع الشبكة العصبونية المصممة أن تعمل بوجود علاقات غير خطية وتوفر أداء جيد في تقدير حالة القناة على الوصلة الهابطة انطلاقاً من حالتها على الوصلة الصاعدة، بالإضافة إلى ذلك، أكدت دراسة أداء النظام من ناحية معدل الخطأ في البت أن استخدام التعلم العميق في تقدير حالة القناة جيد جداً حيث تناقصت قيمة هذا المقدار بشكل واضح في حالة السيناريو من نمط القطع الزائدي كما في الشكل (9).

ملاحظة: النظام قائم على تقنية الهوائيات الكثيفة ولكن قمنا بدراسة تحليل تأثير المكونات اللاخطية على حالة القناة وهذا

يقلل من أداء النظام. أي أن نظام **Massive MIMO** بوجود ظاهرة المكونات اللاخطية يحتاج لتدريب وتعلم لتقديم أداء أفضل في تقدير حالة القناة والتي تعتبر من أهم المشكلات التي تواجه هذا النظام وهي محور بحث قائم لدى الباحثين في هذا المجال.

تظهر النتائج أيضا أن طرق التعلم العميق لها إمكانيات كبيرة في حل العديد من مشاكل تقدير المعاملات في الاتصالات،  
على سبيل المثال تقدير القناة في أنظمة Massive MIMO

## 6- References

- [1] C. Huang, L. Liu and C. Yuen, " Asymptotically Optimal Estimation Algorithm for the Sparse Signal With Arbitrary Distributions," *IEEE Trans. on Veh. Technol.*, vol. 67, 2018.
- [2] C. Huang, L. Liu, C. Yuen and S. Sun, "Iterative Channel Estimation Using LSE and Sparse Message Passing for MmWave MIMO Systems," *IEEE Trans. on Signal Proces.*, vol. 67, 2019.
- [3] D. Rumelhart, G. E. Hinton and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, Oct 1986.
- [4] E. G. Larsson, O. Edfors, F. Tufvesson and T. L. Marzetta, " Massive MIMO for next generation wireless systems," *IEEE Commun. Mag.*, vol. 52, 2014.
- [5] F. Rusek, D. Persson, B. K. Lau, E. G. Larsson, T. L. Marzetta, O. Edfors and F. Tufvesson, "[4] Scaling up MIMO: Opportunities and challenges with very large arrays," *IEEE Signal Process. Mag.*, vol. 30, 2013.
- [6] J. Duchi, E. Hazan and Y. Singer, " Adaptive subgradient methods for online learning and stochastic optimization," *J. Machine Learning Research*, Jul 2011.
- [7] J. G. Andrews, S. Buzzi, W. Choi, S. V. Hanly, A. Lozano, A. C. K. Soong and J. C. Zhang, " What will 5G be?," *IEEE J. Sel. Areas Commun.*, vol. 32, 2014.
- [8] L. Lugosch and W. J. Gross, "Neural offset min-sum decoding," IEEE ISIT, Aachen, Germany, 2017.
- [9] T. J. O'Shea, K. Karra and T. C. Clancy, "Learning to communicate: Channel auto-encoders, domain specific regularizers, and attention," Proc. IEEE ISSPIT, Limassol, Cyprus, 2016.
- [10] T. Yoo and A. Goldsmith, " Capacity and power allocation for fading MIMO channel with channel estimation error," *IEEE Trans. Inf. Theory*, May 2006.
- [11] W. Xu, Z. Wu, Y. Ueng, X. You and C. Zhang, "Improved polar decoder based on deep learning," Proc. IEEE SIPS, Lorient, France, 2017.