التنبؤ بمخاطرة أسعار الصرف باستخدام الشبكة العصبونية-دراسة تطبيقية

م.د. كفاء علي عيسى أبورغيف

الجامعة المستنصرية / كلية الادارة والاقتصاد

P: ISSN : 1813-6729
E : ISSN : 2707-1359
http://doi.org/10.31272/JAE.44.2021.129.4

تأريخ أستلام البحث : 26/ 7 /2021 **مقبول للنشر بتأريخ : 2021/8/29**

المستخلص:

تتميز تقنية الشبكات العصبونية (Neural Networks) بقدرتها على معالجة المدخلات ومعطيات الواقع وتجاوز التقنيات التقليدية في تفسير سلوك الظواهر، مما جعلها مثار اهتمام العديد من الباحثين في المجالات المختلفة. يهدف البحث الى الإفادة من القدرات المتميزة للشبكة العصبونية عند استخدامها في اتخاذ قرارات الإستثمار لاسيما في مجال العملات كونه أحد مجالات الإستثمار المهمة سواء على مستوى الأفراد أم المؤسسات المالية بهدف تحقيق الأرباح، والتي تعتمد أساساً على التنبؤ بتحرك أسعار العملات صعوداً أو نزولاً. تم استخدام ثلاث أنواع من تقنيات الشبكات العصبونية وهي: تقنية الشبكة العصبية الشعاعية المحدثة (Modified Radial Basis Function(MRBF)) وتقنية الشبكة العصبية متعددة الطبقات (multi-layer perception (MLP)) وأخيراً تقنية الشبكة العصبية الاصطناعية(artificial neural network (ANN)) لتحقيق أهداف البحث. تم إجراء التحليل باستخدام معلومات شهرية عن سعر صرف اليورو مقابل الدولار الأمريكي للمدة من 1/1/2015 لغاية 31/12/2020 ، و تم استخدام برنامج (MATLAB, V.5.2.0) لمعالجة بيانات الإدخال وبالتالي الحصول على نتائج البحث. توصل البحث الى ان استخدام الشبكة العصبونية (ANN) يعطي دقة كبيرة في التنبؤ بالتحركات المستقبلية للعملة عينة البحث قياساً بالتقنيات الأخرى المستخدمة حسب معيار المقارنة RMSE ، الأمر الذي يقلل من مخاطرة الإستثمار في العملات وبالتالي زيادة العوائد.

الكلمات المفتاحية: الشبكة العصبونية، مخاطرة أسعار الصرف ، التنبؤ.

المبحث الأول- منهجية البحث:

1.1 مشكلة البحث :

تنال تحركات أسعار العملات اهتمام الشركات والمستثمرين في معظم البلدان ، إذ تتغير أسعار صرف العملات بصورة مستمرة مما ينعكس على قيمة الأصول والخصوم والأرباح والخسائر المتوقعة، فضلاً عن التعرض لمخاطرة أسعار الصرف، وهذا يدفع كل من الشركات والمستثمرين للبحث عن الوسائل المناسبة لزيادة قدرتهم في توقع تحركات أسعار الصرف. من هنا، ترتبط مشكلة البحث بالتساؤل عن مدى قدرة الشبكات العصبونية في توفير فهم أفضل في توقع تحركات أسعار الصرف وتحسين قدرة المستثمرين في اتخاذ القرار الإستثماري الصحيح وتقديم وسيلة للإستدلال والتنبؤ الدقيق عن أنماط تحركات أسعار صرف العملات.

1.2 أهمية البحث:

تنبع أهمية البحث من ارتباطها بجانبين: يتعلق الأول بالعملات باعتبارها أهم الموجودات المتداولة في الأسواق سواء في مجال الإستثمار أو اجراء المعاملات، والجانب الثاني يرتبط بتغيير أسعار الصرف والذي ينتج نوعاً من اللاتأكد عند التخطيط للإستثمار مما قد يؤدي الى آثار سلبية أو إيجابية على صافي الثروة، وهذا يجعل البحث عن وسيلة مناسبة للتنبؤ ومتابعة اتجاهات أسعار العملات ينعكس في تقليل حالات عدم التأكد بالبيئة علاوة على اتخاذ قرارات أفضل عند اختيار العملات.

1.3 أهداف البحث:

تمثل الشبكات العصبونية تقدمًا كبيرًا على أنظمة التداول القائمة على القواعد، والتي تتطلب خبرة ودراية كبيرة لتحديد قواعد التداول لتمثيل ديناميكيات السوق. ومن المستحيل عملياً توقع أن أحد الخبراء يمكنه وضع قواعد تداول تراعي وتعكس بدقة ظروف السوق المتقلبة والمتغيرة بسرعة، إذ أن النظم غير المرنة والقائمة على القواعد ليست قابلة للتكيف ديناميكيًا على الرغم من عمليات إعادة التحسين الدورية لمؤشرات النظام. وعلى العكس من نظم التداول الفنية التقليدية القائمة على القواعد والتي كانت شائعة في ثمانينيات القرن الماضي، فإن النظم العصبونية لا تحتاج إلى قواعد تداول محددة مسبقًا أو "تحسين" المؤشرات الفنية لإنشاء إشارات تداول. واستناداً لذلك يهدف البحث الحالي الى تقديم أساس منهجي يعتمد على إمكانية التنبؤ بأسعار العملات باستخدام الشبكات العصبونية، فضلاً عن تقييم أداء ثلاث أنواع من التقنيات المستندة الى الشبكات العصبونية وتحديد أفضلها من حيث التنبؤ بمخاطرة تقلب أسعار الصرف.

1.4 مجال البحث:

نظرًا لأن مجال التنبؤ المالي كبير جدًا، فقد تم الإقتصار في هذا البحث ليشمل سوق الصرف الأجنبي، وتحديداً قيمة اليورو الأوروبي مقابل الدولار الأمريكي، واللذان يعدان من أهم العملات في سوق الصرف الأجنبي. تم اختيار اليورو كمجال محدد للبحث لأنه يمثل ثاني أهم عملة في سوق الصرف الأجنبي بعد الدولار الأمريكي. وقد تم الاعتماد على سعر الإغلاق للمدة من 1/1/2015 لغاية 31/12/2020 لسعر الصرف الفوري في مقابل الدولار الأمريكي إعتماداً على البيانات المنشورة ألكترونياً في الموقع https://sa.investing.com/currencies/eur-usd-historical-data

1.5 أدوات البحث:

تم استخدام ثلاث أنواع من تقنيات الشبكات العصبونية وهي: تقنية (MRBF) وتقنية (MLP) وأخيراً تقنية (ANN) للحصول على نتائج البحث النهائية وتحديد أفضلها.

المبحث الثاني- الجانب النظري للبحث

2.1 مفهوم سعر الصرف:

شهد سوق الصرف الأجنبي تطوراً غير مسبوقاً خلال العقود القليلة الماضية الذي إنتقل فيه العالم إلى مفهوم القرية العالمية. ويعد سعر الصرف أحد الأسواق المالية الرائدة في العالم، ويعبر عن السعر الذي يمكن من خلاله استبدال عملة بلدٍ ما بعملة بلد آخر. تمثل العملات أحد الموجودات الأساسية التي تسعى الشركات العالمية والمستثمرين الحصول عليها لأغراض الإستثمار أو الإقتراض أو إجراء تعاملات مالية مختلفة. كما يعرف سعر الصرف بأنه عدد الوحدات من عملة معينة والتي يمكن مبادلتها بوحدة واحدة من عملة أخرى.(Solis,2012:83) أو تمثل عملة بلد معين معبراً عنها في ضوء عملة أخرى (Jordan et al,2011:604) . كما يعبر عنه بأنه المعدل الذي يتم به تحويل عملة محلية الى عملة أجنبية (Bodi et al, 2011:730). ويشير كذلك الى السعر المدفوع لتحويل عملة معينة الى عملة أخرى(Madhumathi&Ranganatham,2012:306) . وقبل عام 1973 كان يسود نظام سعر الصرف الثابت اعتماداً على إتفاقية بريتون وودز ليتم التحول بعدها نحو أسعار الصرف العائمة.(Madura&Fox,2007:72)، (James,2012:127)،(Bodie et al,2011:730)

وذكر (Cecchetti,2011:275) بأنه يمكن تصنيف أسعار الصرف الى أنواع عديدة وهي سعر الصرف الإسمي (Nominal) الذي يمثل المعدل الذي يمكن من خلاله تبادل عملة بلد معين مع عملة بلد آخر. وسعر الصرف الفعلي (Real)الذي يعبر عن المعدل الذي يمكن تبادل سلع وخدمات بلد معين مع سلع وخدمات بلد آخر، أي بمعنى كلفة سلع بلد معين مقارنة مع بلد آخر. وسعر الصرف الآني (Spot) وهو السعر الذي يتم به تسليم العملة فورياً. وأخيراً سعر الصرف الآجل (Future) وهو سعر بيع وشراء العملات في المستقبل.

يلعب سعر الصرف دورًا مهمًا في التحكم في ديناميكيات سوق الصرف. لذلك ، يعد التنبؤ المناسب بأسعار الصرف عاملاً حاسمًا لتحقيق النجاح في العديد من الأعمال والاستثمارات وما إلى ذلك في جميع أنحاء العالم. (Chandrasekara & Tilakaratne,2009:1-2)

2.2 العوامل المؤثرة في سعر الصرف:

ذكر (سلمان،2016: 5) عدد من العوامل التي يمكن أن تؤثر على سعر الصرف وهي:

- مستويات الأسعار النسبية : حسب نظرية تعادل القوة الشرائية ، عندما ترتفع أسعار السلع المحلية ينخفض الطلب على السلع المحلية ويتجه سعر العملة الوطنية نحو الإنخفاض حيث يمكن الإستمرار في بيع السلع المحلية بطريقة جيدة، والعكس صحيح .
- التعريفات الجمركية والحصص : تؤثر في سعر الصرف كل من التعريفات الجمركية (الضرائب على السلع المستوردة مثلا) والحصص (القيود على كمية السلع التي يمكن إستيرادها)، لأن ذلك يزيد من الطلب على السلعة المحلية .
- تفضيل السلع الأجنبية على السلع المحلية : زيادة الطلب على صادرات دولة ما يتسبب في إرتفاع عملتها على المدى الطويل ، وزيادة الطلب على الواردات تسبب في إنخفاض قيمة العملة الوطنية
- الإنتاجية : في حال كانت الدولة أكثر إنتاجية من غيرها من الدول، يمكن أن تخفض أسعار السلع المحلية بالنسبة لأسعار السلع الأجنبية وتظل تحقق أرباحاً، والنتيجة هي زيادة الطلب على السلع المحلية وميل سعر العملة المحلية إلى الإرتفاع.

2.3 سوق صرف العملات الأجنبية:

يعد سوق الصرف الأجنبي أحد أكثر الأسواق الديناميكية تعقيدًا ويتميز بخصائص التقلب الشديد وعدم الخطية وعدم الانتظام. ومنذ انهيار نظام بريتون وودز في السبعينيات ، أصبحت التقلبات في سوق الصرف الأجنبي أكثر تقلبًا من أي وقت مضى. فضلاً عن ذلك ، فإن بعض العوامل المهمة مثل النمو الاقتصادي وتطوير التجارة وأسعار الفائدة ومعدلات التضخم ، لها تأثيرات كبيرة على تقلبات أسعار الصرف، هذه العوامل تجعل أيضًا من الصعب جداً التنبؤ بأسعار صرف العملات الأجنبية. لذلك ، أصبح التنبؤ بأسعار الصرف قضية بحثية مهمة للغاية وتحديًا لكل من المجتمعات الأكاديمية والصناعية. (Yu, et al, 2007:1)

يتركز الإطار التقليدي لدراسة أسواق العملات الدولية في الوظائف المعيارية للعملة باعتبارها واسطة للتداول ووحدة للحسابات ومخزن للقيمة. ويختلف دور العملة بالنسبة للسوق عنها بالنسبة للحكومة والتي تمثل بالنسبة لها أداة لتثبيت سعر الصرف وعملة للإحتياطي، أما بالنسبة للأسواق فهي تلعب دوراً في تداول النقد الأجنبي ومجال للإستثمارات (Cohen,2009:26) ، (Cecchtti et al,2011:262). ويتميز سوق العملات بتنوع أدواته وبالمنافسة العالية وإن بدت سيادة الدولار واضحة بعد أن اعتلى عرش عملات الإحتياطي خلف الجنيه الإسترليني بعد أن كان يمثل النسبة المئوية الأعلى من الإحتياطات عام 1945 لينخفض بعد ذلك الى 25% عام 1965. (Queen et al, 2020:6123) .وتعد سوق العملات واحدة من أكبر الأسواق المالية، وليس لسوق العملات مكان محدد بل تجري معظم التعاملات ألكترونياً، ومع إزالة القيود والمحددات على انتقال رؤوس الأموال شهدت التعاملات بالعملات قفزات كبيرة. ففي لندن تم تداول حوالي (753) بليون دولار من النقد يومياً في ابريل 2004. ويتداول يومياً حوالي (400) بليون دولار في أسواق نيويورك وطوكيو، وبلغ معدل التداول اليومي للتعاملات بالعملات عام 2007 حوالي 3.2 تريليون دولار. (Cecctt et al,2011:278) و (Jaimes,2015:196)و(Jordan et al,2011:603) . وهناك العديد من المشاركين في سوق العملات كالمستوردين وشركات الأعمال والمصارف والمتداولين والمضاربين(Jordan etal,2011:604). وبسبب تقلب أسعار العملات نتيجة للسياسات الحكومية وظروف السوق فإن ذلك يؤثر في قيمة السلع والخدمات المقومة بتلك العملات مما يجعل بعضها أكثر تنافسية مع ارتباطها بانخفاض العملة المقومة بها السلع أو أقل تنافسية بسبب ارتفاع أسعارها نتيجة ارتفاع العملة، ففي عام 1997 انخفضت أسعار عملة العديد من البلدان الآسيوية بسبب الأزمة المالية، وهذا انعكس في جعل سلعها أرخص (Madura&Fox,2007:52)، كما يؤثر في ارتفاع أو انخفاض قيمة ما يملكه الأفراد والشركات من العملات. وهناك العديد من العوامل المؤثرة في تقلبات أسعار الصرف مثل معدل التضخم ومعدل سعر الفائدة وعرض العملة والطلب عليها وسيطرة الحكومة والتوقعات (Madura&Fox,2007:137) .

2.4 مخاطرة أسعار الصرف :

إن التنبؤ بأسعار الصرف مهمة صعبة للغاية ، ولهذا السبب فإن الكثير من الشركات والمستثمرين يتحوطون ببساطة من مخاطر عملاتهم، ومع ذلك يمكن لأولئك الذين يسعون الى التنبؤ بأسعار الصرف ويريدون فهم العوامل التي تؤثر على تحركاتها استخدام هذه الأساليب، فوجود توقعات لسعر الصرف لإتخاذ القرارات مهم للغاية لتقليل المخاطر وتحقيق أقصى قدر من العائدات. (Nguyen, 2019:1) يرتبط التعريف الشائع لمخاطرة سعر الصرف بتأثير التغيرات غير المتوقعة في أسعار الصرف على قيمة الشركة على وجه الخصوص ، ويعرف بأنه إمكانية تحقق الخسارة المباشرة أو غير المباشرة في التدفقات النقدية للشركة، والأصول والخصوم، وصافي الربح، وبالتالي القيمة السوقية للأسهم نتيجة لتقلبات حركة سعر الصرف. ولغرض إدارة مخاطرة سعر الصرف تحتاج الشركات الى تحديد نوع المخاطرة التي يمكن أن تتعرض لها، فضلاً عن تشخيص استراتيجية التحوط والأدوات المتاحة للتعامل مع مخاطرة التحركات المحتملة للعملات.(Papaioannou,2006:3) . وقد أصبحت مخاطرة أسعار الصرف تحتل أهمية أكبر في ظل عولمة وتدويل الأسواق العالمية، وهي واحدة من أصعب المشاكل بسبب كونها ذات طبيعة مستمرة مما يتطلب من المديرين التنفيذيين الماليين التعامل معها والتغلب عليها (Al-Momani & Gharaibeh, 2008:198). ويشير (Jacque, 1996:14) الى أن المديرين الذين يستمرون في تجاهل مخاطرة تقلبات أسعار الصرف الأجنبي هم من الأنواع الذين ينتهون بسرعة، إذ تشير إدارة مخاطرة أسعار الصرف الأجنبي إلى الإدارة الاستباقية لتقلبات العملات التي تؤثر على التدفقات النقدية وسعر السهم. وبالتالي، فإن الغرض منها هو زيادة قيمة المساهمين من خلال ضمان ثبات تدفق أرباح الشركة. ويرتبط التعامل في أسواق العملات بأنواع عديدة من المخاطر يحددها (Madura&Fox,2007) وتتمثل بـ: (Hallgren et al, 2006:31-34)

2.4.1 مخاطرة التعاملات Transaction Risks

وهي تعبر عن كيفية تأثير التغير في أسعار صرف العملات على قيمة التدفقات النقدية لأسعار الصرف المتوقعة المقومة والمتعلقة بالمعاملات المبرمة، وتشمل التعاملات طويلة الأمد وقصيرة الأمد. وهي تتمثل بعدم التأكد فيما اذا كانت المتحصلات المستقبلية قادرة على تغطية الذمم الدائنة للشركة ، وبالتالي فهي تعبر عن إحتمال ربح أو خسارة الشركة نتيجة لتقلبات أسعار الصرف.

2.4.2 مخاطرة التحويل Translation Risks

وتسمى أحياناً بالمخاطرة المحاسبية ، وتشير الى امتلاك الشركة فروع أجنبية أو أصول حقيقية في البلدان الأجنبية. وتنشأ هذه المخاطرة عندما تكون البيانات المالية للفروع الأجنبية التي تملكها الشركة في بلدان أخرى بعملة البلد الموجودة فيه، ولابد من تحويل هذه العملات الى عملة البلد الأم من أجل توحيد البيانات المالية للشركة الأم. عندها ستكون قيمة أصول وخصوم هذا الفرع بعملة مغايرة لعملة الشركة إذ ستكون بالعملة المحلية، ونتيجة لذلك ستكون قيمتها مختلفة عن قيمتها الحقيقية نتيجة لاختلاف سعر الصرف في البلد الموجود فيه، من هنا ستحقق الشركة أرباحاً أو خسائر إعتماداً على حركة أسعار صرف العملات .

2.4.3 المخاطرة الإقتصادية Economics Risks

ويطلق عليها أحياناً بالمخاطرة الاقتصادية، أو المخاطرة التنافسية أو الإستراتيجية. وهي تقيس أي تغير يحدث في القيمة الحالية للشركة الناتجة عن التغير في التدفقات النقدية التشغيلية المستقبلية الناتجة عن أي تغير غير متوقع في أسعار الصرف. إن تقلبات العملات التي تتسبب في تغير حجم المبيعات المستقبلية للشركة والأسعار والتكاليف تؤدي الى تغير في قيمة الشركة، وهي ذات العوامل التي تؤدي الى التغير طويل الأمد في تنافسية الشركة. بعبارة أخرى فإن المخاطرة الاقتصادية تقيس كيف يمكن لتقلبات العملة أن تتسبب في تغير القيمة الاقتصادية للشركة. فيما يحدد (Rose et al, 2013:595) مخاطرة أسعار الصرف بمخاطر تعرض طويلة الأجل ومخاطر التعرض قصيرة الأجل ومخاطر التعرض للمعاملات. إن زيادة المخاطر المرتبطة بتداول العملات يدفع باتجاه البحث عن أفضل وسيلة للتنبؤ بتحركات أسعارها سواءاً لتحقيق أرباح أو لتنفيذ سياسات معينة، فضلاً عن المحاولات المستمرة للعثور على أنماط ثابتة للأنظمة المعقدة في مجالات عديدة كالفيزياء والكيمياء والإقتصاد. وتعد الأسواق المالية أنظمة معقدة تضم ملايين المشترين والمضاربين والعديد من العوامل المترابطة بشكل كثيف مما يتطلب تحديد إمكانية اتباع الأنماط قانون معين يمكن التنبؤ به. (Mark,2009:272) و (Jaimes,2015:269) .

2.5 تقنيات التنبؤ بمخاطرة أسعار الصرف:

خلال الفترات الماضية استخدمت نماذج كثيرة للتنبؤ بسعر الصرف للعملات الأجنبية ومن اكثر هذه النماذج شيوعا كان نموذج التمهيد الاسي ونماذج ARIMA ، ويعتمد النموذج الاسي على المشاهدات للفترات السابقة ولكنه غير قادر على التنبؤ بالصفات غير الخطية المتواجدة خلال السلسلة الزمنية، وغالبا ما تكون النماذج الخطية غير كفوءة في التنبؤ للسلاسل الزمنية المعقدة (الجراح والحكاك، 2013 :361). يعد التنبؤ بسعر الصرف من خلال استخدام السلاسل الزمنية أحد أكثر التطبيقات تحديًا في الوقت الحاضر، إذ أن الأسعار بطبيعتها غير ثابتة ومتذبذبة، وتشير هذه الخصائص إلى أنه لا توجد معلومات متكاملة يمكن الإفادة من خلالها للتوقع بشكل مطلق بمعدلات الأسعار في المستقبل، ونتيجة لذلك، فإن البيانات التاريخية تعد اللاعب الرئيسي أو المدخلات في عملية التنبؤ. وتعد نمذجة السلاسل الزمنية هي التقنية التقليدية المستخدمة للتنبؤ بأسعار الصرف والتحول الى الشبكات العصبية كبديل لطرق التنبؤ الإحصائي التقليدية. (Chandrasekara & Tilakaratne,2009: 2)

لذا، لابد لمديري الشركات والمستثمرين فهم تقنيات التنبؤ للمساعدة في اتخاذ قرارات التحوط من تحركات أسعار العملات أو في اتخاذ قرار التمويل قصير الأجل وطويل الأجل. وهناك العديد من التقنيات المستخدمة في التنبؤ بتحركات أسعار صرف العملات وهي: (Madura&Fox,2007:332) .

2.5.1 التحليل الفني Technical Analysis

ويستخدم عادةً من قبل المضاربين الذين يحاولون الإستفادة من التحركات اليومية لسعر الصرف. ويعتمد هذا الأسلوب على استخدام البيانات التاريخية في التنبؤ بتحركات أسعار الصرف باستخدام نماذج مثل نظرية Daw والشموع والرسوم البيانية في اكتشاف أوقات انخفاض او ارتفاع أسعار العملة.

2.4.2 التحليل الأساسي Fundamental Analysis

يعتمد هذا الأسلوب على تأثير العوامل الاقتصادية في أسعار الصرف ومحاولة التنبؤ بتحركات الأسعار في ضوء التغيرات بتلك العوامل من خلال الإستفادة من القيم الحالية لتلك المتغيرات وتأثيرها التاريخي في سعر العملة يمكن تطوير تنبؤات بالأسعار المستقبلية.. ومن خلال بناء نماذج اقتصادية باستخدام أسلوب الإنحدار يمكن التنبؤ بأسعار الصرف في ضوء مجموعة من العوامل الإقتصادية مثل سعر الفائدة والتضخم . (Sollis,2012:184)

2.4.3 الشبكات العصبونية Neural Networks

وهي نماذج تعود جذورها الى العلوم البايولوجية والعصبية والتي تهتم بدراسة كيفية تمكن الكائنات الحية من تطوير حلول من أجل البقاء(Kumar&Walia,2006:61)، وهي تحاكي نموذج الشبكة العصبية للإنسان.(Thawornwong&Enke,2004:207). وتعد الشبكة العصبونية أو العصبية أداة بديلة قوية لنمذجة البيانات قادرة على التقاط وتمثيل علاقات الإدخال / الإخراج المعقدة (Philip et al, 2011: 2). تتكون الشبكات العصبونية من عدد من العصبونات neurons المترابطة ببعضها. وتختلف هيكلية الشبكات العصبونية من حيث هذه الارتباطات. يطلق على الشبكات العصبونية عدة مصطلحات منها الأنظمة العصبية، أو أجهزة الكمبيوتر العصبية، أو الأنظمة الذكية. يتم تصميمها على غرار بنية ووظيفة الدماغ البشري، نظرًا لأنها يمكن أن تتعلم أو تتدرب أو تعمم نتائج التجارب السابقة. (Nasution & Agah, 2000::220). وهي تعد من التقنيات الحديثة المستخدمة في البيئة المالية، وقد زادت تطبيقاتها في مجال الأعمال عموماً وفي المجال المالي بشكل خاص. (Maditinos, et al, 2002:3) و (Thanornwong&Enk,2004:206). وقد زاد استخدام الشبكة العصبونية في المجال المالي لاسيما في ظل تطور تقنيات تكنولوجيا المعلومات والاتصالات والتي وفرت مدى واسع من الخيارات الاستثمارية للمستثمرين (Maditinos, et al, 2002:3) مما يتطلب استخدام أدوات قادرة على مساعدة المستثمرين في التنبؤ بتحركات الأدوات الاستثمارية واتخاذ القرار المناسب في بيع أو شراء تلك الأدوات. هناك العديد من العوامل التي لابد من تحديدها عند بناء الشبكة العصبية وهي عدد الطبقات (المدخلات والمخرجات والطبقات المخفية) وعدد العقد في كل طبقة وما إلى ذلك. وهناك عدد كبير من العوامل التي يمكن أن تؤثر على تدريب الشبكة العصبية واختيار بنية الشبكة ، ووظيفة التنشيط ، وخوارزمية التدريب ، والأوزان الأولية ، وعدد الطبقات المخفية ، وما إلى ذلك ، لذلك يجب استخدام كل هذه العوامل للتوصل إلى أفضل نموذج للشبكة العصبية الذي يمكن استخدامه للتنبؤ. وبالتالي، غالبًا ما يساعد نهج التجربة والخطأ أو تجربة التحقق المتبادل في العثور على أفضل نموذج. عادة ما يتم النظر في عدد كبير من نماذج الشبكة العصبية. يتم اختيار التقنية التي تتمتع بأفضل أداء في مجموعة التحقق باعتبارها الأفضل. وأثناء التدريب، تتم مقارنة كل ناتج مرغوب مع المخرجات الفعلية ويتم حساب مجموع الخطأ التربيعي في طبقة الإخراج. (Chandrasekara & Tilakaratne, 2009:4)

2.4.3.1 نقاط القوة والضعف في الشبكات العصبية

لنمذجة الشبكات العصبونية ثلاث مزايا رئيسة مقارنة بالنمذجة الإحصائية التقليدية نوردها بما يلي: (SUN, 2005: 23-24)

- أنها تتفوق على نماذج الانحدار الخطي في نمذجة العلاقات غير الخطية لأن دوال التنشيط اللاخطية في استخدام الشبكات العصبية يمكن أن تلتقط بشكل أكثر فاعلية ميزات الأنماط اللاخطية.
- أنها تقلل من افتراضات الدوال المطلوبة في النمذجة غير الخطية الأخرى. ومن المحتمل أن يتسبب نقص المعرفة في حدوث خطأ عن طريق اختيار دالة خاطئة في نموذج الانحدار ، مما يقلل بشكل كبير من دقة التنبؤات في النماذج غير الخطية الأخرى.
- أخيرًا ، تعتبر البنية في الشبكات العصبية مرنة نسبيًا. تتوافق بنية الشبكات العصبية مع مجموعة واسعة من التقنيات الإحصائية المستخدمة غالبًا طالما أن هذه الأساليب الإحصائية تعدل هياكلها قليلاً. هذا يعني أن نمذجة الشبكة العصبية لديها مجموعة متنوعة من القدرات.

ومن ناحية أخرى ، تم أيضًا اكتشاف أربعة جوانب غير مرغوب في الشبكة العصبونية وهي:

- إن وجود طبقة (طبقات) مخفية في الشبكات العصبية يجعل تأثير المدخلات الفردية على المخرجات المتوقعة معقدًا للغاية ويصعب تحديده ، وبالتالي يصعب تفسير الأوزان التي تم تحديدها من الشبكات العصبية .
- من المحتمل أن تكون الحدود الخارجية للتوقعات محجوبة ببعض الحدود الداخلية وبالتالي لا يمكن العثور عليها بسهولة. يحدث هذا غالبًا عند استخدام جميع طرق التقدير غير الخطية .
- تعد العينة الكبيرة ضرورية بشكل خاص للشبكات العصبية لتوفير تنبؤ عالي الجودة لأن الأوزان الكثيرة المتضمنة في الشبكات العصبية (مقارنة بنمذجة الانحدار القياسي) تقلل من درجات الحرية.
- تستغرق مهمة تصميم وتقدير بنية الشبكة العصبية وقتًا طويلاً بسبب الإجراء المعقد القائم على التجربة لبناء الشبكات العصبية.

وبحسب العديد من الدراسات تعد الشبكة العصبية أكثر دقة في التنبؤ بتحركات مؤشر S&P أو بالتدفق النقدي للمصارف ومؤشرات الأسهم والعملات وأسعار الفائدة قصيرة الأجل وتحركات أسواق الأسهم والتنبؤ بمعدل تبادل الأسهم اليومي في مؤشر NASDAQ (Moghaddam et al,2016) .

وفي هذا البحث تم استخدام ثلاث أنواع من الشبكات العصبونية وهي : تقنية (MRBF) وتقنية (MLP) وأخيراً تقنية (ANN) وسيتم مناقشة كل نوع منها فيما يلي :

1- تقنية (MRBF)

وتمثل تقنية (Modified Radial Basis Function(MRBF)) إحدى مجالات الذكاء الصناعي والتي تعد أحد حقول المعرفة الجديدة وميدان علمي يسعى الى فهم ماهية الذكاء البشري، وإيجاد وسائل للقيام بإنجاز مهام ذكية وبلوغ مستوى عالٍ من الأداء لحل مشاكل ومسائل متنوعة(Tan, 2014 :2). ويرتكز عمل الشبكة على معمارية رياضية تعتمد الإستجابة التي تتكيف مع المدخلات، وباستخدام قواعد التعلم تمارس سلسلة مستمرة من عملية التدريب لتحقيق المهام المطلوبة. وهي تتميز بأداء النمذجة غير الخطية، وتصنف كأحد الأساليب الموجهة بالبيانات والتي (على عكس الأساليب الموجهة بالنماذج) لاتتطلب تقديراً للمعالم التي تستخدم بالتنبؤ أو توظيف مسبق خلال عملية النمذجة. (Thawarnwang&Enke,2004:207) . تتميز تقنية(MRBF) بسهولة البناء والتعامل مع حجم كبير من البيانات وحل عدد متنوع من المشاكل وبأساليب مختلفة فضلاً عن حل المشاكل التي يصعب على الخبراء حلها (Tan,2014 :19). ويتطلب استخدام هذه الشبكة حجم ملائم من البيانات واحتوائها على معلومات يتم من خلالها توصيف المشكلة وفهم أدوات الشبكة (Kumar&Walin,2006:62). وهي توفر أداة لايمكن للنماذج الإحصائية والإقتصادية التنبؤ بها كمياً بسبب تعقيدها وعدم القدرة على إيجاد دوال خاصة بها . يتلخص عمل هذا النوع من الشبكات العصبونية بإدخال البيانات الخاصة بالمجتمع الأولي (العملات) ثم تعمل تقنية (MRBF) على تدريب البيانات المدخلة ومن ثم مقارنة الحل الذي تم التوصل اليه في كل دورة مع البيانات الأخرى وخزن الحل الأمثل، ثم يتم استبدال الحل الأمثل بعد كل دورة وهكذا الى أن يتم فحص كامل البيانات التي تم إدخالها. وعبر (Rowland et al, 2020:8) عن شبكة MRBF في أبسط أشكالها بأنها شبكة عصبية أمامية ثلاثية الطبقات. تتوافق الطبقة الأولى مع مدخلات الشبكة، والطبقة الثانية عبارة عن طبقة مخفية تتكون من سلسلة من وحدات التنشيط غير الخطي، وتتوافق الطبقة الأخيرة مع المخرجات النهائية للشبكة كما مبين في الشكل (1) .

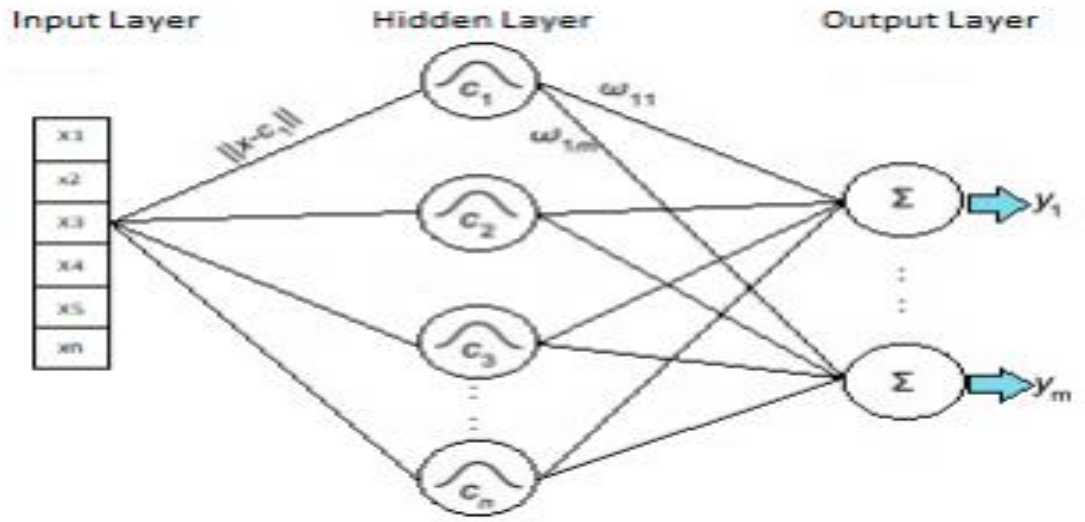

الشكل (1)
بنية شبكة MRBF

Source: Faris, Hossam, Ibrahim Aljarah, and Seyedali Mirjalili. 2017. Evolving Radial Basis Function networks using Moth-Flame optimizer. Handbook of Neural Computation, 537–50. .

2- تقنية (MLP)

النوع الآخر من تقنيات الشبكات العصبونية الذي سنتناوله يسمى multi layer perception (MLP) أي الشبكات العصبونية متعددة الطبقات أو المستويات، والشكل (2) يوضح شبكة نموذجية متعددة المستويات، حيث أن عقد الادخال تستخدم لادخال بيانات السلسلة الزمنية (أسعار الصرف المنشورة) بينما عقد الاخراج تستخدم لحساب التنبؤات (أسعار الصرف المتوقعة)، أما العقد المخفية والتي ترتبط بدالة تحويل ملائمة فهي تستخدم لمعالجة البيانات المستلمـــة من عقـــد الادخـــال. إن شبكة الإدراك الحسي متعدد الطبقات MLP تحتوي على طبقة مخفية واحدة أو أكثر بين طبقات الإدخال والإخراج، وعند ترتيب الخلايا العصبية في طبقات، يتم توجيه الاتصالات دائمًا من الأسفل إلى طبقات أعلى ، مع عدم وجود ترابط بين الخلايا العصبية في نفس الطبقة (Tavish, 2014:2))

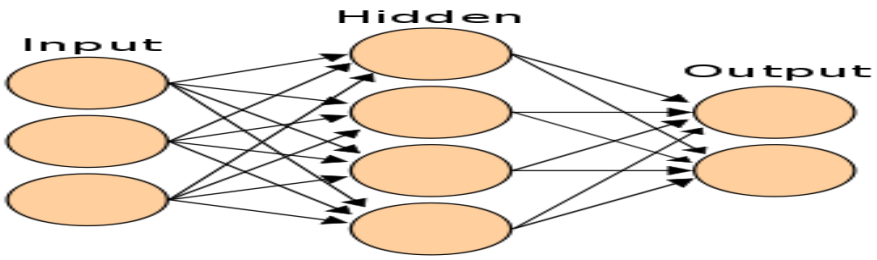

الشكل (2)
بنية شبكة MLP

Source: Srivastava, Tavish,(2014), "How does Artificial Neural Network (ANN) algorithm work? Simplified, Link: https://www.analyticsvidhya.com/blog/2014/10/ann-work-simplified

في المرحلة الاولى لعملية التعلم يتم اعطاء قيم ابتدائية عشوائية لجميع الاوزان، وتستخدم الخوارزمية مجموعة من البيانات خاصة بمرحلة التعلم ويطلق عليها set learning وتتكون من مجموعة بيانات الادخال ومجموعة بيانات المخرجات المفروضة، وكل زوج من بيانات المدخلات والمخرجات يتم الحصول عليه من البيانات التاريخية الخاصة بالسلسلة الزمنية، وتستخدم هذه البيانات لتحديث الاوزان عن طريق حساب اصغر قيمة لمجموع مربعات الخطا (minimize the squared sum of errors) (MSE) المحتسبة عن طريق حساب الفرق مابين قيم مخرجات الشبكة الفعلية والقيم المخططة .وبعد حساب قيمة (MSE) سيتم اجراء التعديلات اللازمة على الاوزان. إن نماذج الشبكات العصبية استخدمت في مختلف البحوث والتطبيقات وعلى سبيل المثال التنبؤ قصير المدى، وتعد نماذج شبكات MLP النماذج الاكثر استخداماً لأن هذه النوعية من الشبكات لديها قابلية لتعلم العلاقات المعقدة مابين مدخلات ومخرجات النموذج والتي يكون من الصعب نمذجتها عن طريق الخوارزميات التقليدية. (الجراح والحكاك، 2013 : 367)

3- تقنية (ANN)

وتشبه الى حد كبير تقنية (MLP) ولكن يضاف لها خاصية الإنتشار العكسي .تعد الشبكة العصبية الاصطناعية (ANN) الأكثر فاعلية في وصف ديناميكيات السلاسل الزمنية غير الثابتة نظرًا لخصائصها غير البارامترية، وقدرتها على التكيف والتعامل مع البيانات غير المستقرة. ANNs يمكنها التعامل مع أي دالة غير خطية دون افتراضات مسبقة حول البيانات. وتكشف الدراسات السابقة أنه يمكن التنبؤ بأسعار الصرف الأجنبي بدقة عالية باستخدام الشبكات العصبية الاصطناعية. يمكن تصنيف شبكات ANN على نطاق واسع إلى فئتين رئيسيتين باستخدام بنيتها وهما شبكات ANNs الثابتة وشبكات ANNs الديناميكية. لا تعتمد المخرجات على المدخلات الحالية فحسب ، بل تعتمد أيضًا على المدخلات والمخرجات السابقة أو حالة الشبكة. (Chandrasekara & Tilakaratne,2009: 2-3)

الشبكة العصبية الاصطناعية تمثل نظام معالجة البيانات ولها خصائص أداء معينة مشتركة مع الشبكات العصبية البيولوجية. تم تطوير الشبكات العصبية الاصطناعية كتعميم للنماذج الرياضية الخاصة بالإدراك البشري أو البيولوجيا العصبية ، بناءً على الافتراضات التالية: (Nasution& Agah, 2000:225)

1. يتم معالجة المعلومات في العديد من العناصر البسيطة التي تسمى الخلايا العصبية.
2. يتم تمرير الإشارات بين الخلايا العصبية عبر روابط الاتصال.
3. كل رابط اتصال له وزن مرتبط به ، والذي يضاعف الإشارة المرسلة اليه.
4. تطبق كل خلية عصبية وظيفة تنشيط (غير خطية عادة) على مدخلاتها الموزونة لتحديد إشارة الإخراج الخاصة بها. يظهر الشكل (3) شبكة عصبية إصطناعية ANN بثلاث طبقات. نوع النظام العصبي الذي تم اختياره لتطوير تطبيقات التنبؤ المالي هو نظام التغذية إلى الأمام والانتشار الخلفي. يتم إنجاز تعليم الشبكة وتدريبها من خلال عملية رياضية تكرارية معقدة، حيث يتم "تدريب" النظام العصبي على بيانات الإدخال باستخدام تحليل الخطأ الإحصائي. وفي أثناء التدريب، كلما كانت توقعات النظام غير صحيحة، يتم تعديل أوزان التوصيل بين الخلايا العصبية لتقليل مثل هذه الأخطاء أثناء التكرارات اللاحقة. يتعلم النظام من خلال انتشار إشارات الخطأ هذه للخلف عبر طبقات الخلايا العصبية لمنع حدوث نفس الخطأ مرة أخرى في كل مرة يتم فيها تقديم المخرجات إلى النظام أثناء التدريب، ومن هنا جاء اسم الانتشار الخلفي. وسيتم تكرار هذه العملية حتى يتم تدريب النظام بنجاح. وبمجرد الانتهاء من هذا التدريب ، سيكون بالإمكان توفير التنبؤات المتوقعة ببساطة. (Nasution& Agah, 2000:226).

إن اختيار تقنية ANN للتنبؤ بمعدلات تغير سعر الصرف يرجع إلى الميزات الفريدة لشبكات ANN وقدرتها القوية على التعرف على الأنماط. على عكس معظم تقنيات التنبؤ التقليدية المستندة إلى النموذج ، فإن الشبكات العصبية الاصطناعية هي فئة من فئات الأساليب المعتمدة على البيانات والتكيف الذاتي وغير الخطية التي لا تتطلب افتراضات محددة بشأن عملية توليد البيانات المستجدة. هذه الميزات جذابة بشكل خاص لحالات التنبؤ العملي حيث تكون البيانات وفيرة أو متاحة بسهولة، على الرغم من أن النموذج النظري أو العلاقة الأساسية معروفة. جدير بالذكر أنه تم تطبيق ANNs بنجاح على مجموعة واسعة من مشاكل التنبؤ في جميع مجالات الأعمال والصناعة والهندسة تقريبًا. بالإضافة إلى ذلك، ثبت أن الشبكات العصبية الاصطناعية تعطي مقاربة عالمية للأحداث يمكنه التقاط أي نوع من العلاقات المعقدة. المصدر ((Yu, et al, 2007:1)

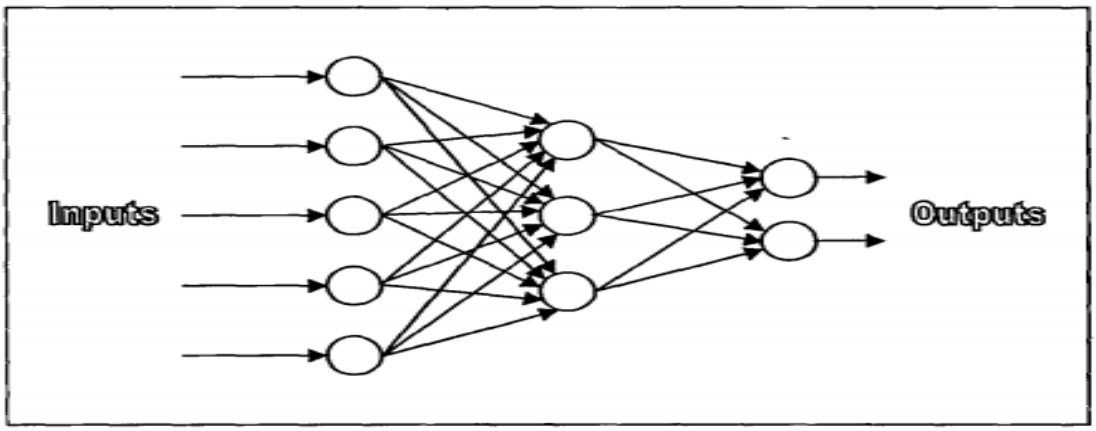

الشكل (3)
بنية شبكة ANN

Source: Nasution, Bona Patria & Agah, Arvin ,(2000), "Currency Exchange Rate Forecasting with Neural Networks", Journal of Intelligent Systems Vol. 10, No. 3, pp. 226.

المبحث الثالث- الجانب العملي للبحث

3.1 تحليل بيانات عينة البحث:

يوضح الجدول (1) ملخصاً لبيانات عينة البحث لسعر صرف EUR/USD ومتوسط السعر الشهري المتحقق. ويلاحظ أن أعلى سعر صرف لليورو مقابل الدولار كان (1.2556) في عام 2018 ، في حين كان أدنى سعر صرف في العام (2017) إذ لم يتجاوز (1.034) الأمر الذي يعكس التقلب العالي لهذه العملة. وحقق عام (2018) أعلى قيمة لكل من سعر الفتح (1.2414) وسعر الإغلاق (1.242) في حين بلغ سعر الفتح وسعر الإغلاق لعام (2017) أدنى قيمة لكل منهما وهي (1.0531) و (1.0513) على التوالي . وهذا يعكس ارتفاع صرف اليورو مقابل الدولار في العام (2018) وانخفاضها لعام (2017) قياساً بالسنوات الأخرى التي شملتها الدراسة. تم الحصول على بيانات البحث من الموقع الاتي: https://sa.investing.com/currencies/eur-usd-historical-data وللمدة من (1/1/2015) لغاية (31/12/2020) .

جدول (1)
البيانات الرئيسة لسعر صرف اليورو مقابل الدولار للمدة (2015-2021)

السنة	التاريخ	سعر الإغلاق	سعر الفتح	السنة	التاريخ	سعر الإغلاق	سعر الفتح
2020	Dec-20	1.2213	1.1928	2017	Dec-17	1.1996	1.1904
	Nov-20	1.1928	1.1658		Nov-17	1.1902	1.1646
	Oct-20	1.1647	1.1719		Oct-17	1.1644	1.1818
	Sep-20	1.1718	1.1936		Sep-17	1.1812	1.191
	Aug-20	1.1936	1.1783		Aug-17	1.1908	1.1842
	Jul-20	1.1774	1.1233		Jul-17	1.184	1.1421
	Jun-20	1.1231	1.1097		Jun-17	1.1423	1.1243

	May-20	1.1098	1.0956		May-17	1.1241	1.0907
	Apr-20	1.0955	1.1031		Apr-17	1.0895	1.0661
	Mar-20	1.1029	1.1003		Mar-17	1.0649	1.0576
	Feb-20	1.1025	1.1092		Feb-17	1.0575	1.0798
	Jan-20	1.1093	1.1213		Jan-17	1.0795	1.0531
2019	Dec-19	1.121	1.1014	2016	Dec-16	1.0513	1.0589
	Nov-19	1.1015	1.1152		Nov-16	1.0585	1.098
	Oct-19	1.115	1.09		Oct-16	1.0979	1.1236
	Sep-19	1.0898	1.0989		Sep-16	1.1238	1.1158
	Aug-19	1.0989	1.1076		Aug-16	1.1156	1.1177
	Jul-19	1.1074	1.1376		Jul-16	1.117	1.1106
	Jun-19	1.1368	1.1168		Jun-16	1.1104	1.1132
	May-19	1.1167	1.1215		May-16	1.1129	1.1446
	Apr-19	1.1215	1.1218		Apr-16	1.1454	1.138
	Mar-19	1.1217	1.1371		Mar-16	1.1378	1.0872
	Feb-19	1.137	1.1447		Feb-16	1.0871	1.0833
	Jan-19	1.1444	1.1466		Jan-16	1.0834	1.0861
2018	Dec-18	1.1469	1.1314	2015	Dec-15	1.086	1.0568
	Nov-18	1.1315	1.1311		Nov-15	1.0563	1.1015
	Oct-18	1.131	1.1608		Oct-15	1.1005	1.1177
	Sep-18	1.1608	1.1596		Sep-15	1.1176	1.1211
	Aug-18	1.1599	1.1691		Aug-15	1.1211	1.097
	Jul-18	1.1691	1.1651		Jul-15	1.0987	1.1141
	Jun-18	1.1683	1.1693		Jun-15	1.1135	1.0986
	May-18	1.169	1.2077		May-15	1.0987	1.1223
	Apr-18	1.2077	1.2323		Apr-15	1.1222	1.0735
	Mar-18	1.2321	1.2194		Mar-15	1.073	1.1188
	Feb-18	1.2193	1.2414		Feb-15	1.1193	1.1285
	Jan-18	1.242	1.2002		Jan-15	1.1286	1.2098

جدول (2)

إحصائيات سعر صرف EUR/USD للمدة (2015-2021)

السنة	الوسط الحسابي	الإنحراف المعياري	أعلى قيمة	أدنى قيمة
2020	1.147058	0.042422271	1.2311	1.0637
2019	1.117641667	0.015811781	1.1571	1.0878
2018	1.178133333	0.036316418	1.2556	1.1214
2017	1.139	0.051465603	1.2093	1.034
2016	1.103425	0.027783	1.1616	1.0352
2015	1.102958333	0.021122281	1.211	1.0457

يبين الجدول (2) الأوساط الحسابية والإنحرافات المعيارية وأعلى وأدنى قيمة لأسعار صرف اليورو مقابل الدولار للعينة التي شملها البحث، ويوضح الجدول (2) أن أعلى قيمة للوسط الحسابي كانت (1.178133333) تحققت في العام (2018) وأدناها (1.102958333) في العام (2015) ، أما من حيث الإنحراف المعياري فقد حقق العام (2017) أعلى قيمة (0.051465603) والعام (2019) أدنى قيمة (0.015811781)، مما يعكس التقلب الكبير في أسعار الصرف للعام (2017) وتقلباً أقل للعام (2019) . وبالرغم من عدم وجود هامش عالي للفرق بين أعلى وأدنى سعر فإن المدة التي شملها البحث شهدت تقلباً واضحاً بين الصعود والهبوط وإن كان ضمن حدود ليست عالية. وتوضح الأشكال (1-6) أدناه تقلبات سعر صرف اليورو مقابل الدولار الأمريكي للمدة (2015-2021):

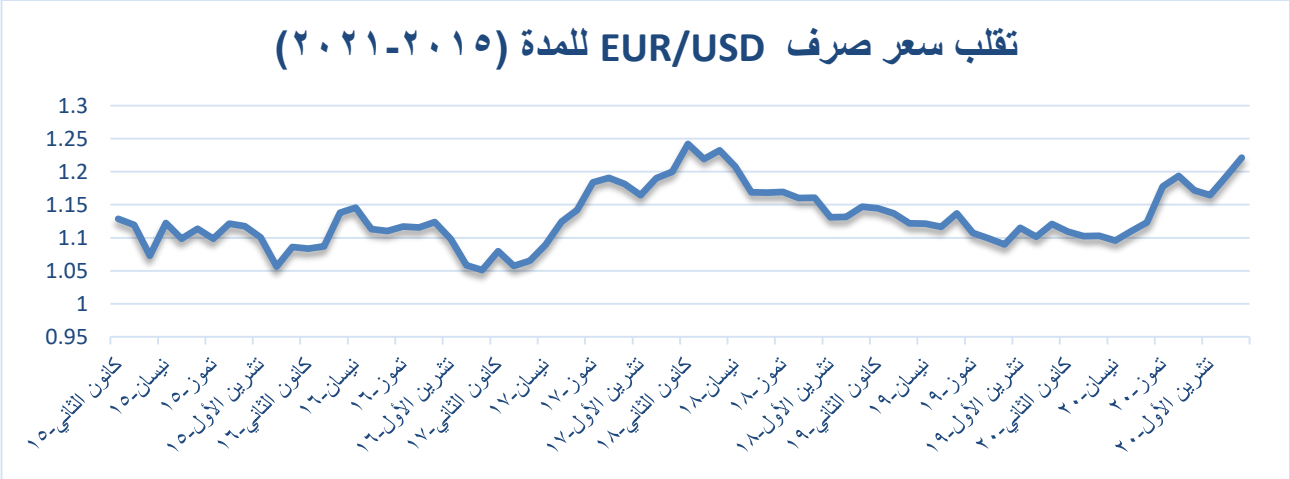

الشكل (4)

تقلب سعر صرف EUR/USD للمدة (2015-2021)

يظهر الشكل (4) تقلباً واضحاً في سعر صرف اليورو مقابل الدولار، إذ بدأ مستقراً الى حدٍ ما خلال العام 2015 لينتهي العام بانخفاضاً ملحوظاً، ارتفع بعدها في بداية العام 2016 وينهي العام بالانخفاض ليبدأ مع بداية عام 2017 بالارتفاع الكبير في النصف الأخير من العام 2017 وبلغ ذروته بداية عام 2018 ، ثم بدأ انخفاضاً تدريجياً بلغ أدنى مستوى له في منتصف العام 2018 ليستقر بعدها الى حدٍ ما مع بداية 2019 حتى نهايتها ليبدأ بعدها اتجاهاً صعودياً حتى نهاية العام 2020 ليبلغ ذروته في الأشهر الأخيرة منه. ويلاحظ من الشكل (1) اتجاهاً متقلباً بين الصعود والهبوط في بداية مدة البحث مسجلاً أعلى مستوى في فترتين هما بداية عام 2018 ونهاية عام 2020 .

3.2 التنبؤ بأسعار الصرف باستخدام الشبكات العصبونية:

سيتم استخدام التقنيات الثلاث للشبكات العصبونية وهي تقنية (MRBF) وتقنية (MPL) وأخيراً تقنية (ANN) لأجل التنبؤ بأسعار صرف EUR/USD. وتمثل أسعار الصرف وأيام التعامل مدخلات للشبكة العصبونية، أما مخرجات الشبكة فتمثل أسعار الصرف. وقد تم استخدام برنامج (MATLAB, V.5.2.0) في تنفيذ التقنيات الثلاثة والاعتماد على معدل الخطأ النسبي MSE لتحديد مدى كفاءة كل تقنية من التقنيات آنفة

الذكر. ويبين الجدول (3) نتائج استخدام التقنيات الثلاث في التنبؤ بأسعار الصرف خلال مدة البحث والمفاضلة بينها من خلال قياس دقة التنبؤ لكل منها .

جدول (3)
مقارنة بين التقنيات الثلاث للشبكات العصبونية لتحركات أسعار الصرف

ت	نوع الشبكة العصبونية	RMSE	دقة التنبؤ%
1	ANN	0.407	92.652%
2	MRBF	0.932	78.125%
3	MLP	1.198	70.55%

إن تقييم أداء الشبكة سيعتمد على انحراف قيمة التنبؤ عن السعر الفعلي للعملة. وتعكس النتائج السابقة انحرافاً منخفضاً للتنبؤ بأسعار الصرف عن التحركات الفعلية خاصة عند استخدام تقنية (ANN). ولغرض تحديد مدى دقة تقنية (ANN) في مقابل الأساليب الأخرى للتنبؤ لتحديد مدى إمكانية الإعتماد عليها من قبل المستثمرين في متابعة وتوقع تحركات أسعار الصرف ، يوضح الجدول (3) مقارنة دقة التنبؤ بين أساليب التنبؤ الثلاث ، إذ يظهر الجدول أعلاه أن تقنية (ANN) تتفوق على الأساليب الأخرى وبفارق كبير، إذ بلغت قيمة متوسط مربع الخطأ النسبي(RMSE) (0.407) وهي تمثل أقل قيمة مقارنة بكل من تقنية MRBF و MLP واللتان حققتا قيم MRSE (0.932) و (1.198) على التوالي. كما تفوقت قنية ANN من حيث دقة التنبؤ إذ حققت (92.652%) في حين سجلت تقنية MRBF (78.125%)، وأخيراً سجلت تقنية MLP (70.55%) .
ويبين الشكل (5) توضيحاً بيانياً لإمكانية الأساليب المختلفة سالفة الذكر في دقة التنبؤ لأسعار العملات، إذ تعكس إمكانية وقدرة تقنية (ANN) في توليد نتائج أفضل في متابعة واكتشاف أنماط مخاطرة تحركات أسعار الصرف.

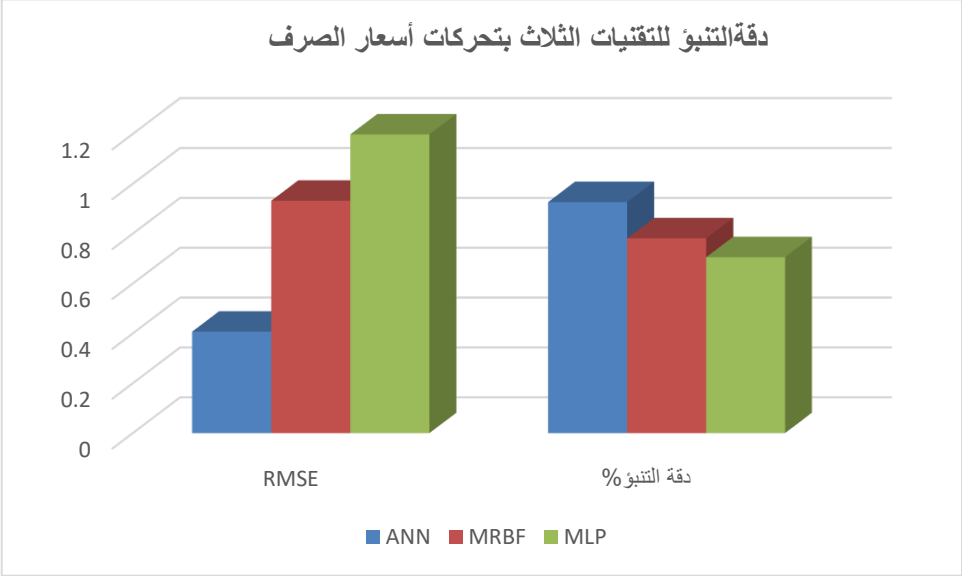

الشكل (5)
دقة التنبؤ لتحركات أسعار صرف عملة ERU/USD للتقنيات الثلاث

المبحث الرابع: الإستنتاجات والتوصيات

أولاً- الإستنتاجات

1- هناك متغيرات كثيرة تؤثر على أسعار صرف اليورو/ الدولار. منها العوامل السياسية والاقتصادية والصحية والبيئية وغيرها ، الأمر الذي يؤثر على استقرار سعر الصرف بشكل عام.
2- كلما كانت بيانات السلسلة الزمنية قريبة من الزمن المطلوب التنبؤ بتحركات أسعار الصرف خلاله كلما ازدادت دقة التنبؤات، إذ سيتم استخدام هذه البيانات كأساس للتنبؤ بسعر الصرف للفترة اللاحقة في كل طريقة على حدة. وعلى هذا الأساس ستزداد دقة التنبؤ بأسعار الصرف فيما لو كانت البيانات المعتمدة يومية .
3- كلما ازداد حجم العينة المستخدمة وازداد عدد المشاهدات كلما كانت نتائج التنبؤ أكثر دقة للشبكات العصبية على اختلاف أنواعها كونها تعطي نتائج أكثر دقة مع ازدياد حجم البيانات اللاخطية المتاحة.
4- من أجل الحصول على أفضل قيمة للتنبؤ، فإن تحديد كل من معلمات خوارزمية التدريب والإعداد وعدد الطبقات ،والخلايا العصبية المخفية في كل طبقة واختيار تركيبة الإدخال المناسبة تعد عوامل مهمة تؤثر على دقة التنبؤات الناتجة من التقنيات الثلاث.
5- كلما زاد عدد الطبقات المخفية في الشبكة العصبية ، يصبح التقارب أكثر والنتائج أكثر دقة. لذا لابد من اختيار أنسب عدد من الطبقات المخفية في كل طريقة اعتماداً على الخوارزمية المستخدمة.
6- حققت تقنية (ANN) نتائج دقيقة وقريبة جداً من التحركات الفعلية لأسعار صرف عملة EUR/USD قياساً بالتقنيات الأخرى.
7- يمكن للمستثمرين إستخدام هذه التقنية لغرض تجنب المخاطرة الناتجة عن تقلبات أسعار الصرف أو تقليلها الى أدنى حد ممكن.

ثانياً- التوصيات

1- من الممكن تطوير تقنيات الشبكات العصبية وتحديثها من خلال القيام بدمج برامجيات الذكاء الإصطناعي الأخرى والخوارزميات المختلفة لبناء أنظمة هجينة يمكن من خلالها التنبؤ بأسعار الصرف من أجل الحصول على نتائج أكثر دقة.
2- يوصي الباحث بإمكانية استخدام تقنية (ANN) في السوق المالي العراقي من أجل تجنب المخاطرة الناشئة عن التحركات غير المتوقعة لأسعار الصرف.
3- ضرورة تطوير عمل السوق المالي العراقي ورفده بالوسائل الحديثة والتقنيات المتطورة لغرض مواكبة التطور التكنولوجي في مجال التنبؤ والتداول بالعملات المختلفة.
4- في هذا البحث تم الاعتماد على سعر صرف اليورو الأوروبي الى الدولار الأمريكي لأن كلا العملتين تعدان اللاعب الرئيسي في سوق الصرف على مستوى العالم. لذا يمكن توسيع هذه الدراسة للتنبؤ بأسعار صرف العملات الأخرى أيضًا باستخدام تقنيات الذكاء الصناعي المتعددة.
5- بالإمكان أيضًا مقارنة أداء الشبكات العصبية مع أداء النماذج الأخرى المستخدمة لتنبؤات السلاسل الزمنية اضافة الى استخدام الأساليب الإحصائية والتي توفر تصوراً ممكنًا لتحركات أسعار الصرف المستقبلية.

المصادر :

1- الجراح ، نوال و الحكاك، ندى (2013)، "إستخدام الطرق الهجينة في التنبؤ لسعر الصرف للدولار الأمريكي مقابل الدينار العراقي"، مجلة كلية بغداد للعلوم الاقتصادية الجامعة ، العدد 34، 359-380.
2- سلمان، ماهر محسن، "التنبؤ بإحتمالات تغير سعر صرف الدينار العراقي مقابل الدولار الأمريكي بإستعمال سلاسل مارآوف للفترة (2008-2014)" ، البنك المركزي العراقي / المديرية العامة للإحصاء والأبحاث / قسم بحوث السوق المالية.
3- Al-Momani, Riad & R. Gharaibeh, Mohammad. (2008). Foreign exchange risk management practices by Jordanian nonfinancial firms. Journal of Derivatives & Hedge Funds. Palgrave Macmillan .Vol. 14 , Nos. 3/4, pp. 198–221.

4- Bodie, Z. Kane, A. and Marcus, A. (2011). Investment and Portfolio Management. 9E McGraw-Hill. USA.
5- Chandrasekara, N. V & Tilakaratne, C. D. (2009). Forecasting exchange rates using Artificial Neural Networks, Sri Lankan Journal of Applied Statistics, 10 (2009): 187 – 201.
6- Chandrasekara, N.V. & Tilakaratne , C.D. (2014), " Forecasting Exchange Rates using Artificial Neural Networks", Sri Lankan Journal of Applied Statistics, No.10, pp. 187-201.
7- Cochetti, S. Schoenholtz, K.and Fackler, James. (2011). Money, Banking and financial market. 3E McGraw-Hill. USA.
8- Cohen. B. 2009. Future of the reserve currency. Finance and Development. September(2009).
9- Hallgren ,Anna, Ljung, Nils-Petter & Temler Linda . (2006) .Swedbank, Bachelor Dissertation, Department of Business Studies. pp. 1-85.
10- https://sa.investing.com/currencies/eur-usd-historical-data
11- Jacque, Laurent L. (1996). Management and Control of Foreign Exchange Risk. Kluwer Academic Publishers. Currency Risk Management-A case study of two Swedish mid-corps
12- James, R. (2012). Currency Wars: The Making of the Next Global Crisis. Penguing Group. USA.
13- Jordan, B. Westerfield, R. and Ross, S. (2011). Corporate Finance essential. 7E. McGraw-Hill. U.S.A.
14- Kumar, P. and Walia, E. (2006). Cash Forecasting:An Application of Artificial neural networks in finance. International Journal of Computer Science & Application 111 (1).
15- Lean Yu , Shouyang Wang & Kin Keung Lai, (2007). "Foreign-Exchange-Rate Forecasting With Artificial Neural Networks," International Series in Operations Research and Management Science, Springer, number 978-0-387-71720-3.
16- Madhumathi, R. and Ranganatham. M. (2012). Derivatives and Risk management. Pearson. Delhi.
17- Maditinos, Dimitrios, Chatzoglou and Prodromos. (2002). The Use of neural networks in forecasting. Review of Economic Science 6 .
18- Madura, J. and .Fox, R. (2007). International financial management. Thomson Learning. UK.
19- Mark, B. (2008). The Social Atom. Al.dar Masriah. Al-lubnaniah. Egypt.
20- Michael G. Papaioannou. (2006) . Exchange Rate Risk Measurement and Management: Issues and Approaches for Firms. International Monetary Fund (IMF) . No. 06/255. pp. 1-20.
21- Moghaddam, A. Moghaddam. M.and Esfandyari, M. (2016). Stock market index prediction using artificial neural network. Journal of Economic. Finance. Administrative Science. Wo.21.
22- Nasution, Bona Patria & Agah, Arvin ,(2000), "Currency Exchange Rate Forecasting with Neural Networks", Journal of Intelligent Systems Vol. 10, No. 3,pp. 219-253.
23- Nguyen, Joseph,(2019), "4 Ways to Forecast Currency Exchange Rates, Investopedia, pp. 6-10, Link :

https://www.investopedia.com/articles/forex/11/4-ways-to-forecast-exchange-rates.asp.

24- Philip, Adewole Adetunji, Taofiki, Akinwale Adio & Bidemi, Akintomide Ayo, (2011) "Artificial Neural Network Model for Forecasting Foreign Exchange Rate", World of Computer Science and Information Technology Journal (WCSIT) ISSN: 2221-0741 Vol. 1, No. 3,pp.110-118.

25- Queen, Abdulkadhim M., Alborgeef, Kafaa Ali, & Jebur, Tuka Kareem, (2020), "Predicting exchange rate future movements by Applying Modified Genetic Radial Basis Function Neural Network, Journal of Xi'an University of Architecture & Technology, Volume XII, Issue IV, pp.6121-6138.

26- Ross, S. Westerfield, R. Jordan, B. and Biey, J. (2013). Corporate Finance. McGraw – Hill. U.S.A.

27- Rowland, Zuzana, Lazaroiu, George & Podhorská, Ivana,(2020) ,"Use of Neural Networks to Accommodate Seasonal Fluctuations When Equalizing Time Series for the CZK/RMB Exchange Rate", MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.

28- Sollis, R. (2012). Empirical finance for finance and Banking. John Wiley Sons Ltd. U.K.

29- SUN, Yawen (2005), "Exchange Rate Forecasting with An Artificial Neural Network Model: Can We Beat a Random Walk Model?', A thesis submitted in partial fulfilment of the requirements for the degree of Master of Commerce and Management (M.C.M.), Lincoln University .

30- Tan, C. (2014). An Artificial neural network primer with financial application examples in financial distress predictions and foreign exchange hybrid trading system. Data Science Association. Paper Academic.

31- Tavish ,Srivastava,(2014), "How does Artificial Neural Network (ANN)algorithm work? Simplified, Link: https://www.analyticsvidhya.com/blog/2014/10/ann-work-simplified.

32- Thawornwong, S.and Enke, D. (2004). The adaptive selection of financial and economic variables for use with artificial neural network. Neuro Computing Wo:56.

Abstract:

Neural Networks technology is characterized by its ability to process inputs and reality data and bypassing traditional techniques in explaining the behavior of phenomena, which has made it a topic of interest to many researchers in different fields. The research aims to take advantage of the distinct capabilities of the neural networks when using it in making investment decisions, especially in the field of currencies, as it is one of the important areas of investment, whether at the level of individuals or financial institutions with the aim of achieving profits, which depends mainly on predicting the movements of currency prices up or down. Three types of neural networks technologies were used: Clustering Modified Radial Basis Function (MRBF), (Multi-layer perception (MLP) technology and finally (Artificial neural network (ANN)) technology to obtain the search results. The analysis was carried out using monthly information on the exchange rate of the euro against the US dollar for the period from 1/1/2015 to 31/12/2020, and MATLAB version V.5.2.0 was used to process the input data and thus obtain the search results. The research found that the use of a neural network (ANN) gives great accuracy in predicting the future movements of the currency of the research sample compared to other techniques used according to the RMSE comparison standard, which reduces the risk of investing in currencies and thus increases returns.

Keywords: neural network, exchange rate risk, prediction.