

استخدام الشبكات العصبونية في شبكات الحساسات اللاسلكية

الدكتور جمال خليفة*

مهند عيسى**

(تاريخ الإيداع 8 / 4 / 2014. قُبل للنشر في 26 / 6 / 2014)

□ ملخص □

دفع التشابه الكبير الموجود بين الشبكات العصبونية وشبكات الحساسات اللاسلكية وآلية عملها بعض الباحثين إلى فكرة دمج التقنيتين معاً، لكن محدودية إمكانات الحساسات اللاسلكية لم تشجع على تطبيق الفكرة في بادئ الأمر، إلا أن الدراسات الحديثة في هذا المجال أثبتت أنه، في ظروف عمل معينة، وفي كثير من التطبيقات تكون بعض الخوارزميات المطورة في الشبكات العصبونية، وغيرها من تقنيات الذكاء الصناعي، كالمنطق الغائم والخوارزميات الجينية، قابلة للعمل بسهولة في بيئة الحساسات اللاسلكية، مع أخذ محدودية إمكانات الحساسات من حيث قدرة المعالجة والطاقة المتوفرة بالحسبان، وكذلك يمكن أن تكون خصائص الشبكات العصبونية الفريدة مفيدة جداً لتحسين أداء شبكة الحساسات اللاسلكية وللقيام بمهام معالجة لا يمكن القيام بها بالطرق التقليدية. سنقوم باستكشاف المجالات المختلفة التي حاول الباحثون فيها إثبات إمكانية استخدام الشبكات العصبونية في نظم شبكات الحساسات اللاسلكية، وسنقوم بتصنيفها بحسب الغاية المرجوة من استخدام الشبكة العصبونية مع تبيين نتائج الدراسات وما توصلت إليه في هذا المجال.

الكلمات المفتاحية: شبكات الحساسات اللاسلكية، الذكاء الصناعي، الشبكات العصبونية.

* أستاذ مساعد - قسم هندسة الاتصالات والالكترونيات - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - سورية.

** ماجستير - هندسة الاتصالات - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - سورية.

Using Artificial Neural Networks in Wireless Sensor Networks

Dr. Jamal Khalifeh*
Mohannad Issa**

(Received 8 / 4 / 2014. Accepted 26 / 6 / 2014)

□ ABSTRACT □

The big similarities between Artificial Neural Networks and Wireless Sensor Networks led some researchers to the idea of combining these two technologies together, but limited sensor recourses didn't encourage to actually perform it, however recent researches show that in a special situations and in many applications Some algorithms developed within Artificial Neural Networks (ANN) and other Artificial Intelligence AI technologies Like Fuzzy Logic Genetic Algorithms May easily work in WSN, also the great objectives of ANN may be very useful to improve the performance of WSN and to perform tasks that couldn't be done by classical methods.

This research tries to explore various research related to using ANN in WSN, and classifies them according to the purpose of using ANN, also clarifies the results of these research.

Keyword: Wireless Sensor Networks WSN, Artificial intelligence (AI), Artificial Neural Networks (ANN).

*Associate Professor, Communication & Electronic Department, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

**Master of science in Communication Engineering. Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

مقدمة:

مكن التقدم العلمي الحديث من تصنيع حساسات منخفضة الاستهلاك للطاقة نسبياً وقليلة التكلفة وصغيرة الحجم، إلا أن هذا التقدم لم يرافقه تقدم مماثل في تصنيع البطاريات، مما جعل موضوع ترشيد استهلاك الطاقة من العوامل الأساسية التي يجب أخذها بالحسبان عند تصميم الشبكة [1] بسبب اعتماد الحساسات اللاسلكية على البطاريات كمصدر أساسي للطاقة، وخصوصاً في الشبكات التي يطلب منها إرسال بيانات إلى المحطة الرئيسية بشكل مستمر مما ينتج كمية ضخمة من البيانات، قسم كبير منها مكرر زمنياً ومكانياً [2].

وبما أن إرسال هذه البيانات إلى المحطة الرئيسية أكثر العمليات كلفة من حيث استهلاك الطاقة في الحساسات [3]، فإن إرسالها كما هي دون معالجة سوف يرهق الشبكة ويهدر طاقتها بشكل كبير، لذلك فهناك ضرورة ملحة لمعالجة هذه البيانات ضمن الشبكة على أن يكون موضوع استهلاك الطاقة هو من العوامل الرئيسية التي يجب أخذها بالحسبان بحيث تكون الطاقة المصروفة على معالجة البيانات أقل من الطاقة اللازمة لإرسال البيانات دون معالجة [4].

إذاً تعد عملية تخفيض حجم البيانات وإلغاء المكرر منها من المواضيع المهمة، وتأتي الفكرة هنا أنه إذا أمكننا استخدام الخصائص الفريدة للشبكات العصبونية في تصنيف البيانات إضافةً إلى مزايا كثيرة أخرى فإننا سنحقق إنجازاً قد يكون أكثر أهمية من الطرق الأخرى المتبعة في هذا المجال .

أهمية البحث وأهدافه:

يهدف البحث إلى دراسة إمكانية استخدام تقنيات الشبكات العصبونية ضمن بيئة عمل شبكات الحساسات اللاسلكية مع الأخذ بالحسبان محدودية شبكة الحساسات اللاسلكية من حيث قدرة المعالجة والذاكرة ومصدر الطاقة، وذلك اعتماداً على الأبحاث المنشورة في هذا المجال، وتبيان النتائج التي توصلت إليها هذه الأبحاث، من أجل تشجيع استخدام تقنيات الذكاء الصناعي في شبكات الحساسات اللاسلكية نظراً للقدرة والميزات المهمة التي سيقدمها استخدام هذه الشبكات لفتح المجال أمام تطبيقات جديدة مبتكرة.

طرائق البحث ومواده:

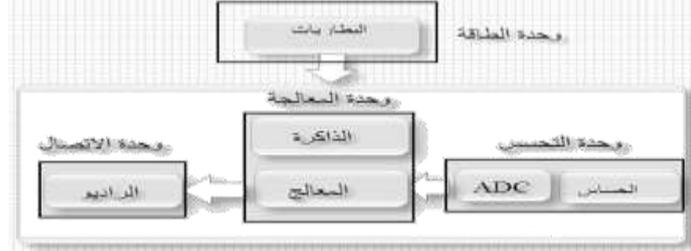
- دراسة الأبحاث حول استخدام الشبكات العصبونية الصناعية في بيئة عمل شبكات الحساسات اللاسلكية.
- تبيان نماذج الشبكات العصبونية المستخدمة والهدف من استخدامها.
- دراسة نتائج الأبحاث ومدى التحسين في عمل شبكة الحساسات اللاسلكية.
- استخدام المحاكى NS2 من أجل نمذجة شبكة الحساسات اللاسلكية في حالتها الاستخدام وعدمه للشبكات العصبونية وذلك لاستقصاء مدى التحسن الذي يقدمه استخدام الشبكات العصبونية.

شبكة الحساسات اللاسلكية.

تتكون شبكة الحساسات اللاسلكية من مجموعة من الحساسات التي تقوم بتحسس الوسط وإرسال البيانات لاسلكياً بمساعدة بعضها بعضاً إلى المكان المطلوب [1].

يتألف الحساس اللاسلكي كما هو مبين في الشكل (1) من معالج وأجهزة تحسس ومصدر للطاقة ومحول تشابهي رقمي ومرسل مستقبل.

يعد الحساس بحد ذاته ضعيفاً ومحدوداً ولكنه يزداد قوةً مع تفاعله مع الحساسات المحيطة به لتشكيل شبكة الحساسات اللاسلكية، ويبين الشكل (1) بنية الحساس اللاسلكي.



الشكل (1) بنية الحساس اللاسلكي [3]

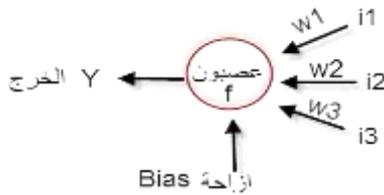
- تستخدم شبكات الحساسات اللاسلكية حالياً في كثير من المجالات ؛ منها:
- المجالات الطبية : كمراقبة حالة المرضى عن بعد.
 - الهندسية : كمراقبة الأنوية والجسور .
 - البيئية : كالزراعة ومراقبة البيئة وكشف الزلازل والحرائق وفي العديد من المجالات الأخرى .

الشبكات العصبونية الصناعية

تعد من أهم تقنيات الذكاء الصناعي وهي نموذج رياضي يحاول محاكاة العمل والذكاء للدماغ البشري. يتكون الدماغ البشري من ملايين الخلايا العصبية التي تتصل مع بعضها بعدد هائل من المحاور المتشعبة ، والطريقة التي تتصل بها هذه الخلايا لتشكيل الدماغ غير مكتشفه حتى الآن [5] [6] ويوضح الشكل (2) ذلك. تتكون الشبكة العصبونية الصناعية من مجموعة من العصبونات الصناعية التي تتصل فيما بينها بوصلات ذات أوزان لتنفيذ الوظيفة المطلوبة ، حيث يكون خرج العصبون تابعاً للمجموع الموزون لقيم الدخل مضافاً إليه الإزاحة ويوضح الشكل (3) بنية العصبون الصناعي

$$Y = f(i_1w_1 + i_2w_2 + i_3w_3 + \text{bias}) \quad (1)$$

حيث i : الدخل، w : الأوزان، bias : الإزاحة.



الشكل (3) بنية العصبون الصناعي



الشكل (2) شبكة عصبونية تحاكي عمل الدماغ البشري

تتكون الشبكة عادة من طبقتين أو ثلاث طبقات: طبقة الدخل، والطبقة المخفية، وطبقة الخرج، وتكون الروابط بين العصبونات بين الطبقة ذاتها والطبقة التي تليها فقط، مع العلم بأن زيادة عدد الطبقات المخفية يساعد في زيادة كفاءة خاصية التحويل غير الخطي بين الدخل والخرج [7].

1.1 التعلم في الشبكات العصبونية

التعلم هو عملية تكرارية يتم من خلالها تغذية الشبكة بنماذج دخل معينة وتعديل أوزان الشبكة العصبونية بحيث نحصل على الخرج المطلوب بطريقة أفضل وأدق، حيث يتم في كل مرة تعديل الأوزان بمقدار Δw والتي تحدد بحسب تابع التعلم المستخدم من أجل تقليل خطأ قيم الخرج إلى عتبه مقبولة [8].
هنالك طريقتان للتعلم:

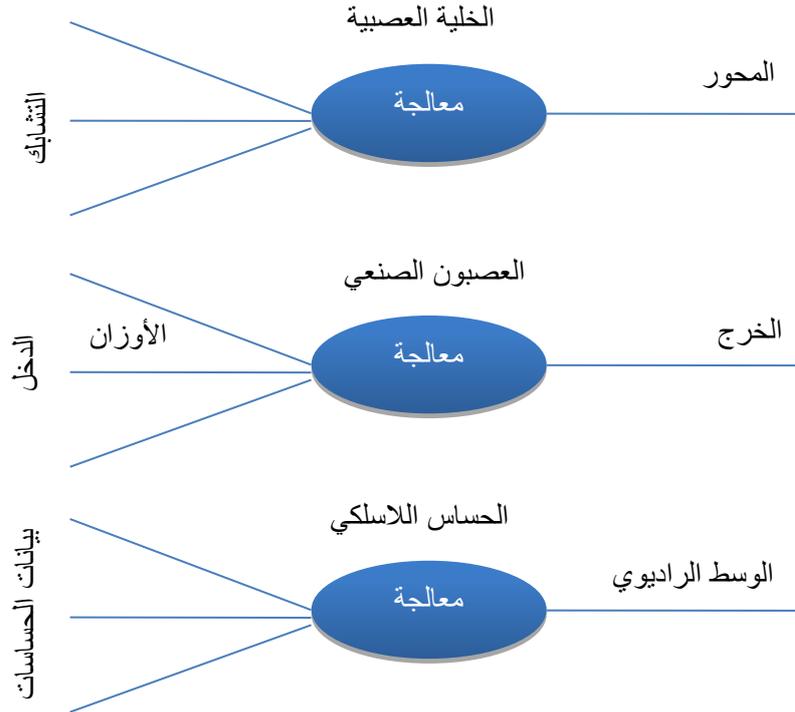
- التعلم غير المراقب : نكتفي بنماذج الدخل لتعديل الأوزان، حيث تقوم الشبكة بتعديل الأوزان بحيث تعطي نماذج الدخل المتشابهة قيم الخرج نفسها.

- التعلم المراقب: نحتاج لنماذج الدخل ونماذج خرج تجريبية لتعديل الأوزان بحيث يعطي الدخل قيمة مقبولة للخرج [3].

استخدام الشبكات العصبونية في شبكات الحساسات اللاسلكية

توجد خصائص مميزة للشبكات العصبونية تجعل من إمكانية استخدامها في شبكات الحساسات اللاسلكية أمراً مثيراً للاهتمام ومن هذه الخصائص [3][1] : المعالجة الموزعة، قابلية التعلم، القدرة على التنبؤ، المرونة، المناعة من الأخطاء والضجيج، الحسابات البسيطة ، والقدرة على تصنيف البيانات بشكل تلقائي.

تتشارك الشبكة العصبونية مع شبكة الحساسات اللاسلكية في كثير من هذه الصفات، الأمر الذي شجع الباحثين على فكرة الربط بين العصبون الصناعي والحساس اللاسلكي، كما نقلوا فكرة تحويل الخلية العصبية إلى عصبون صناعي [9][1]. فهذه الشبكات مكونة من عناصر صغيرة متصلة فيما بينها وكل منها يعمل كتابع يقوم بتحويل قيم الدخل إلى الخرج الموافق، حيث تتم معالجة بيانات الدخل في العصبون الصناعي عن طريق التابع $h(x)$ ، وهو، بشكله المبسط، المجموع الموزون لقيم الدخل. وكذلك يقوم الحساس بتحويل بارامترات البيئة الفيزيائية إلى إشارة كهربائية تتم معالجتها وإرسالها عبر الوسط الراديوي، كما تتم في الخلية العصبية الطبيعية SOMA المعالجة الكيميائية للسايالة العصبية، ويوضح الشكل (4) التشابه بين الخلية العصبية والعصبون الصناعي والحساس اللاسلكي.



الشكل (4) التشابه بين الخلية العصبية والعصبون الصناعي والحساس اللاسلكي [1]

حيث يمكن أن نرى الحساس اللاسلكي بمثابة خلية أو عصبون صناعي، أو رؤية شبكة الحساسات اللاسلكية كشبكة عصبونية، أو أن يحوي الحساس اللاسلكي شبكة عصبونية كاملة بداخله، مع الأخذ بالحسبان العوائق الكثيرة أمام هذه المقاربة [1]. وقد ذهب أحد الباحثين إلى أبعد من ذلك، حيث أطلق تسمية جديدة وهي شبكة الحساسات اللاسلكية العصبونية *Neural Wireless Sensor Network NWSN* وعمل على دمج التقنيتين معاً [9]. مع الانتباه إلى الفوارق أمام هذه المقاربة ومنها أن الشبكة العصبونية لا تحتتمل وصلة ضعيفة ومعرضة للخطأ بين العصبونات كما هو الحال في شبكة الحساسات اللاسلكية، وأن التوزيع العشوائي للحساسات قد لا يكون مناسباً لعمل الشبكة العصبونية. استخدم الباحث برنامج الماتلاب لتدريب الشبكة والحصول على الأوزان، وتمت الاستفادة من هذه الأوزان في التنفيذ المادي للشبكة العصبونية باستخدام *FPGA*.

نماذج الشبكات العصبونية المستخدمة في شبكات الحساسات اللاسلكية

سنقوم فيما يأتي بذكر بعض نماذج الشبكات العصبونية التي استخدمت في الدراسات :

1.2 نموذج شبكة *Self Organizing Map SOM*

يوضح الشكل (5) نموذج شبكة *SOM* وهو من نماذج الشبكات العصبونية ذات التعلم غير المراقب، يؤمن تقليص حجم البيانات وتجميع بيانات الدخل المتشابهة إلى أماكن متقاربة في خريطة الخرج المكونة من العصبونات، وتكون البيانات المختلفة في أماكن متباعدة في خريطة الخرج [10]. والعصبونات الصناعية في هذا النموذج منظمة في طبقتين:

- طبقة الدخل أو طبقة التحسس : تستقبل بيانات الحساسات، حيث يخصص عصبون لكل بت من بتات

الدخل.

- طبقة الخرج أو طبقة التزاحم: تكون متصلة بالكامل مع طبقة الدخل بحيث يتفعل عصبون في الخرج عند نماذج البيانات المتشابهة في الدخل.

1.3 نموذج شبكة Adaptive Resonance Theory ART

يوضح الشكل (6) نموذج شبكة ART وقد طور هذا النموذج من أجل التعرف على النماذج وهو يعتمد على التعلم غير المراقب، ويمكن ضبط بارامترات هذا النموذج بسهولة بحسب متطلبات التطبيق للحصول على تفاصيل أعلى أو أقل عن بيانات الحساسات [2].

تتكون شبكة ART عادة من ثلاث طبقات: طبقة الدخل التي تخزن نموذج الدخل ويكون كل عصبون متصل بكافة عصبونات الطبقة التالية بروابط موزونة، وطبقة التزاحم، وطبقة الخرج أو طبقة التعرف [11].

ولنطوي فكرة عن عمل هذه الشبكة، فإنه عندما يأتي نموذج دخل جديد بعد التعلم يتم مقارنته مع النماذج المخزنة ضمن الشبكة، وتتنافس عصبونات طبقة التزاحم في تمثيل هذا النموذج، فإذا كان هنالك تشابه مع أحد النماذج المخزنة يتفعل العصبون الموافق في طبقة الخرج. وإذا لم يكن كذلك، يتم تفعيل عصبون جديد في الخرج، حيث يتم الاعتماد على المعامل μ لتحديد دقة التشابه المطلوب $\mu = \frac{W_{inX}}{X}$ حيث تعبر W عن الأوزان و X عن نموذج

الدخل، مما يساهم في التحكم بعدد الأصناف المطلوبة بحسب هذا المعامل. وتستمر الشبكة في تفعيل عصبونات جديدة ومن ثم مجموعات جديدة عند نماذج البيانات الجديدة حتى امتلاء الذاكرة المخصصة لعملها [11]. ويتضمن هذا النموذج نماذج فرعية مثل ART1 من أجل البيانات الرقمية و FuzzyART من أجل البيانات التماثلية، وأيضاً نماذج ذات تعلم مراقب مثل ARTMAP، FuzzyARTMAP [2].

1.4 نموذج شبكة HopField

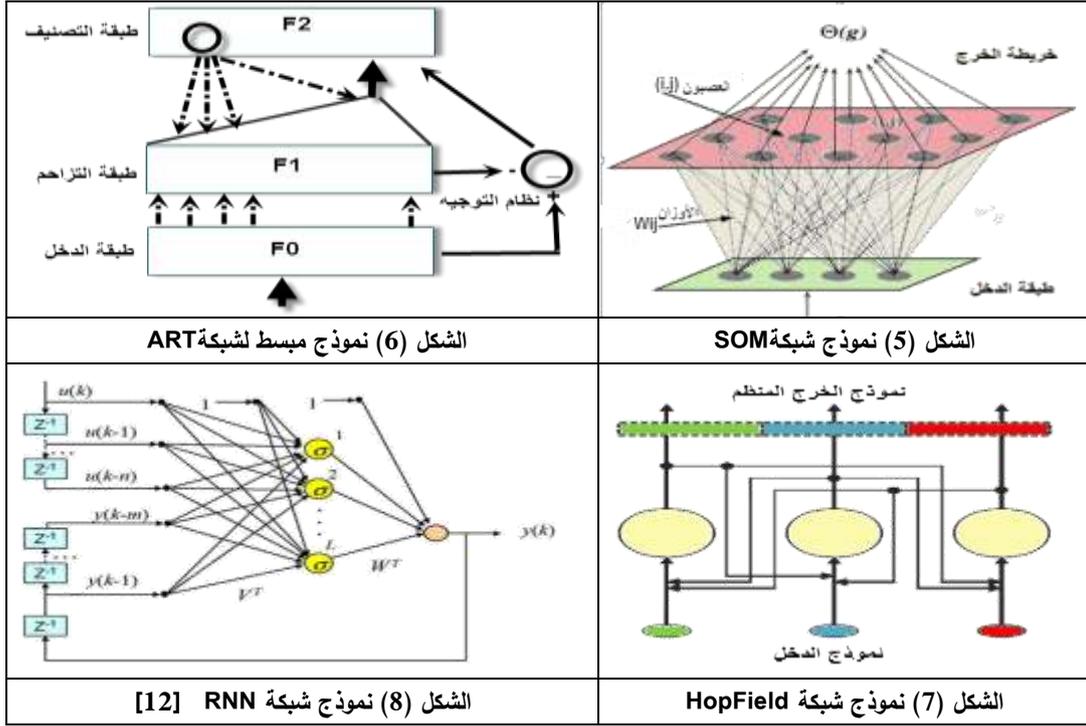
يوضح الشكل (7) نموذج شبكة HopField وهي من النماذج الفريدة في الشبكات العصبونية فهي تتكون من طبقة واحدة ذات تغذية عكسية من خرج كل العصبونات، أي لكل عصبون في الشبكة دون أن يكون هنالك تغذية عكسية للعصبون من خرجه، وتكون الأوزان متساوية بالجهتين [1]. لا تقوم هذه الشبكة بتخزين النماذج في العصبونات كما هي بل تقوم الأوزان في الشبكة بتخزين العلاقة بين النماذج ويمكنها تكلمة بيانات النماذج الناقصة اعتماداً على هذه الخاصية.

1.5 نموذج شبكة Recurrent Neural Networks RNN

يوضح الشكل (8) نموذج شبكة فهذه الشبكة لها قدره جيدة على محاكاة ونمذجة الأنظمة الديناميكية غير الخطية كشبكات الحساسات اللاسلكية وذلك كانعكاس لهيكليتها الديناميكية ذات التغذية العكسية والتغذية المؤخرة [12]، ويستفاد منها في نمذجة التتابع غير الخطية .

1.6 نموذج شبكة Multilayer Perceptron MLP

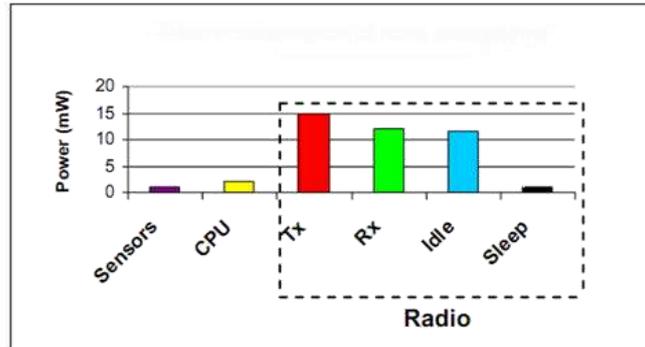
وهي تطوير لشبكة Single Layer Perceptron أبسط نماذج الشبكات العصبونية، تتألف من طبقة دخل وطبقة خرج وعدة طبقات مخفية، ونستفيد من هذه الطبقات المخفية في إضفاء مزيد من قوة المعالجة والمرونة للشبكة. ويتحدد عدد الطبقات وعدد العصبونات في كل طبقة بحسب درجة تعقيد المشكلة التي يطلب من الشبكة حلها [13]. تعتمد هذه الشبكات عادة على التعلم المراقب، وتستخدم خوارزمية Back_Propagation لتعديل الأوزان اعتماداً على الخطأ بين قيمة خرج الشبكة والخرج المطلوب، ويستفاد منها بشكل رئيسي في نمذجة التتابع.



التصنيف حسب الغاية من استخدام الشبكات العصبونية في شبكات الحساسات اللاسلكية

1.7 حفظ الطاقة وزيادة زمن حياة الشبكة

مهما كانت الغاية من استخدام الشبكة العصبونية في شبكة الحساسات اللاسلكية فإن اعتبار حفظ الطاقة هو من الأولويات، وبالنظر إلى الشكل (9) الذي يبين استهلاك الطاقة في الحساس نجد أن الاتصال لإرسال أو استقبال البيانات يستهلك القسم الأكبر من طاقته.



الشكل (9) استهلاك الطاقة في الحساس اللاسلكي [3]

لذلك يجب أن يكون موضوع توفير استهلاك الطاقة من العوامل المهمة في كافة المراحل من العتاد الصلب للحساس نفسه ومدى استهلاكه للطاقة، إضافة إلى الطبولوجيا التي تعمل عليها الشبكة، والبرمجيات والخوارزميات التي تشغيلها، وعادة يتم توفير قسط كبير من الطاقة عندما نطفئ الحساس حين انعدام الحاجة لعمله ويتم ذلك بضبط زمن التشغيل Cycle Duty، وحين لا ندعه يرسل بيانات مكررة أو غير مفيدة ويتم ذلك من خلال تجميع ودمج البيانات ضمن الشبكة. وعندما لا تستنفد طاقته بسرعة أكبر من غيره لأنه ممرٌ لتحويل البيانات بشكل مستمر، أو أن يكون مطلوباً منه القيام بأعمال أكثر من غيره ويتم ذلك باختيار الخوارزميات المناسبة لتوزيع استهلاك الطاقة بشكل متساوٍ

ضمن الشبكة. وبشكل عام نحافظ على طاقة الحساس عندما نقلل من الاتصالات اللازمة لعمله ضمن الشبكة. وبحسب نموذج Heinzelman [14] تصرف الطاقة بشكل أساسي في الإرسال على الترميز والتعديل وباقي العمليات الالكترونية وتقدر معيارياً بـ $E_{elec} = 50 \text{ nJ/bit}$ و ناستهلك الطاقة أيضاً في تضخيم الإشارة بحسب المسافة المراد إرسال البيانات إليها

$$ETX(K, d) = ETx_{elec}(K) + ETx_{amp}(K, d^2) \quad (2)$$

حيث $ETX(K, d)$: الطاقة الكلية المصروفة، K : عدد البتات، d : المسافة.

$ETx_{elec}(K)$: الطاقة المصروفة في الدوائر الكهربائية للمرسل.

$ETx_{amp}(K, d^2)$: الطاقة المصروفة على تضخيم الإشارة في المرسل.

وفي الاستقبال ناستهلك الطاقة على الدارات الالكترونية لاستقبال البيانات $ERx(k) = E_{elec}(k)$

لنفترض أن عملية تجميع أو تصنيف البيانات والتي من خلالها نتمكن من إرسال رقم الصنف بدل نموذج الدخل كاملاً أدت إلى تمثيل K/bit من بيانات الدخل بـ $1/\text{bit}$ من البيانات على خرج الشبكة العصبونية. فعندئذ يكون مجمل الطاقة المصروفة $E(\text{Neural})$ عند استخدام الشبكة العصبونية مساوية للطاقة المصروفة

على معالجة K/bit من بيانات الدخل $E(\text{NDA})$ مضافاً إليها الطاقة المصروفة على إرسال رقم الصنف ETX ، " بإهمال الطاقة اللازمة لتدريب الشبكة والذي يتم بشكل خارجي غالباً "مساوية لـ:

$$E(\text{NEURAL}) = E(\text{NDA}) + E(\text{TX}) \quad (3)$$

وتكون الطاقة اللازمة لإرسال البيانات كما هي دون معالجة

$$E(\text{Custom}) = KE(\text{TX}) \quad (4)$$

فإذا كانت هذه الطاقة $E(\text{NEURAL})$ أقل من الطاقة اللازمة لإرسال بيانات الدخل كما هي دون معالجة

نكون قد حققنا الفائدة من استخدام الشبكة العصبونية.

$$E(\text{Neural}) < E(\text{Custom}) \rightarrow E(\text{NDA}) + E(\text{TX}) < KE(\text{TX}) \rightarrow$$

$$E(\text{NDA}) < (K - 1)E(\text{TX}) \quad (5)$$

يساعد استخدام الشبكات العصبونية في توفير الطاقة بطرق متعددة متعلقة بخصائص هذه الشبكات من حيث القدرة على التصنيف والتنبؤ وتقريب التتابع وسهولة تعديل عملها بضبط بارامترها، وانطلاقاً من فكرة أن زمن حياة الشبكة ينتهي عند نفاذ طاقة أول حساس فيها، وأن في الشبكة أماكن يكون فيها استهلاك طاقة الحساس بشكل أكبر بكثير من مناطق أخرى، فإن التنبؤ بمستوى طاقة تلك الحساسات يمكننا من معرفة الأماكن التي سيتم فيها استهلاك طاقة الحساسات بشكل كبير. وهذا يمكننا من تعديل المسارات أو زيادة عدد الحساسات في هذه الأماكن التي تشكل عنق زجاجة بالنسبة للشبكة. في البحث [15] يقوم الحساس اللاسلكي بجمع معلومات عن موقعه وعن جيرانه، تغذى

هذه المعلومات للشبكة العصبونية للحصول على معلومات يتم منها تحديد الأماكن التي يتم فيها استهلاك الطاقة بشكل أكبر، لذا يتم تعديل مسار التحويل بحيث توفر في الطاقة المصروفة من أجل زيادة زمن حياة الشبكة. وفي البحث [16] قام الباحث بدراسة توفير الطاقة التي يؤمنها استخدام الشبكة العصبونية في تصنيف بيانات الحساس اللاسلكي عند إعادة برمجته، من أجل إزالة الأخطاء أو إضافة وظائف جديدة أو تحديثها. وقام بمقارنة الطرق التقليدية TP في تحديث برنامج الحساس مع طريقة استخدام الشبكات العصبونية Feed forward Network FF C_Mantec Network CM ووجد الباحث توفيراً ملحوظاً في الطاقة المصروفة اللازمة لإعادة برمجة الحساس، لكنه لم يأخذ بالحسبان الطاقة اللازمة لعمل الشبكة العصبونية بالحسبان. وفي البحث [17] درس الباحث توزيع الشبكة العصبونية على الحساسات، ودرس طريقة التحليل والتوزيع المناسبة للشبكة بحيث يتم تقسيم الشبكة العصبونية بعد تدريبها إلى أجزاء قليلة الاتصال لبعضها مع بعض بحيث تعطي النتيجة نفسها، و بحيث يتم تحقيق التوازن بين الذاكرة التي نحتاجها في كل حساس وبين كمية الاتصالات اللازمة في الشبكة، حيث يقلل توزيع الشبكة على عدد كبير من الحساسات من متطلبات الذاكرة في كل حساس ولكنه يزيد عدد الاتصالات في الشبكة، كما أن تخفيض عددها يزيد من حجم الذاكرة المطلوبة.

1.8 تحويل البيانات وإيجاد المسار

يشمل استخدام الشبكات العصبونية ضمن بروتوكولات التحويل في شبكات الحساسات [18]: المساعدة على اختيار مسار تحويل البيانات المناسب، وتجميع الحساسات، واختيار قائد المجموعة.

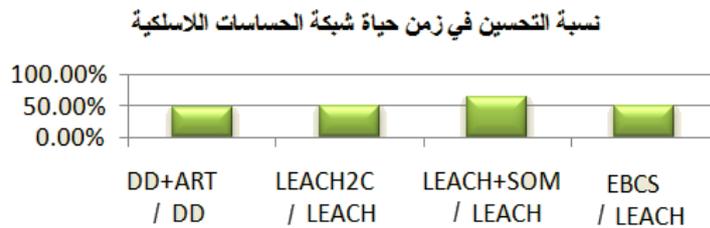
1.8.1 حساب جودة الوصلة اللاسلكية لاختيار المسار المناسب لتحويل البيانات

في شبكات الحساسات اللاسلكية، لا تقوم الحساسات غالباً بإرسال بياناتها مباشرة إلى المحطة المركزية، بل يتم ذلك من خلال مساعدة عدة حساسات وسيطة، حيث يتم اختيار هذه الحساسات الوسيطة اعتماداً على معايير مختلفة كاختيار الحساسات بحيث نحصل على أقصر مسار أو أفضل مسار من حيث الجودة، وكذلك لتحقيق غايات مختلفة كتحقيق معدل نقلٍ عالٍ أو توفير استهلاك الطاقة. ندعو طريقة أو آلية اختيار هذه الحساسات بخوارزمية التحويل، وقد قام الباحثون بالتعديل والتطوير للعديد البروتوكولات المخصصة للعمل في بيئة شبكة الحساسات اللاسلكية ولا يزال التطوير لا يزال مستمراً. قام الباحث في البحث [10] بتعديل خوارزمية Dijkstra لحساب المسارات الأقل كلفة بين كل حساس في الشبكة والحساس المركزي وسمى الخوارزمية الناتجة Sensor Intelligence Routing, SIR حيث يقوم كل حساس بإرسال حزم خاصة إلى العقد المجاورة يحصل من خلالها على معلومات عن مقدار التأخير، و معدل الخطأ، ودورة التشغيل ومعدل النقل للحساسات. تشكل هذه البارامترات الأربعة دخل الشبكة العصبونية الموجودة في كل حساس حيث تقوم هذه الشبكة بحساب جودة الوصلة QoS مع الحساسات المجاورة، تتم الاستفادة من هذه الحسابات ومن حسابات الحساسات المجاورة لحساب المسافة أو كلفة الاتصال بين كل حساس والحساس المركزي من خلال العلاقة: $d(v_i) = d(v_j).QoS$. حيث $d(v_j)$: المسافة، و QoS : جودة الخدمة للوصلة.

وبذلك تنتقل البيانات من حساس إلى آخر حتى الوصول إلى الحساس المركزي بشكل ديناميكي متجنباً الانتقال عبر مسارات تكون فيها كفاءة الوصلة اللاسلكية منخفضة [10]، كما قام الباحث باستخدام نموذجين من الشبكات العصبونية في شبكة الحساسات: النموذج الأول هو شبكة SOM تعمل كقائد مجموعته للحساسات التي تحوي النموذج الثاني HopField، وقد أظهرت هذه الهيكلية قدرة كبيرة على تخفيض كمية البيانات المنقولة عبر الشبكة وعلى تحسين الوثوقية.

1.8.2 تجميع الحساسات واختيار قائد العنقود

تساعد عملية تقسيم شبكة الحساسات اللاسلكية إلى عناقيد أو مجموعات مساعدة كبيرة في تحسين قابلية توسع الشبكة وزيادة زمن حياتها، وقد أثبتت الدراسات فائدة استخدام الشبكات العصبونية في تقسيم شبكة الحساسات واختيار قائد العنقود [19]. أشهر وأول البروتوكولات التي تعمل في الشبكة المدمجة هو بروتوكول LEACH وحقق هذا البروتوكول تحسناً مهماً في أداء الشبكة وقابلية التوسع، ينقسم عمله إلى طور الإعداد الذي يتم فيه اختيار بارامترات العمل واختيار قائد العنقود، وطور العمل الذي يتم فيه تحويل بيانات الحساسات. ونظراً لأهمية هذا البروتوكول فقد طرأت عليه تحسينات كثيرة، في البحث [20] تم الاعتماد على الشبكة العصبونية SOM في اختيار قائد العنقود ضمن المحطة المركزية اعتماداً على موقع الحساس، وبعده عن المحطة الرئيسية وطاقته المتبقية، وعدد المرات التي تم فيها اختيار الحساس كقائد للعنقود، حيث تتنافس الحساسات فيما بينها ضمن الطبقة الثانية للشبكة العصبونية ذات التغذية المباشرة FFNN للفوز برئاسة العنقود، حيث تفوز العقدة ذات الطاقة الأقل استهلاكاً والمرتبطة بنسبة عالية من التسليم الناجح للحزم من الحساس المصدر إلى الحساس الهدف، وأثبت الباحث من خلال المحاكاة تحسن الأداء مقارنة بالبروتوكول LEACH. كما إن استخدام الشبكة العصبونية في البحث [18] ضمن عمل البروتوكول EBCS أدى إلى زيادة زمن حياة الشبكة بشكل ملحوظ مقارنة مع البروتوكولين LEACH و LEA2C الذي يعتمد أيضاً على شبكة SOM في تقسيم الشبكة إلى عناقيد، كما أدى إلى توزيع جيد لاستهلاك الطاقة وتحسين التغطية بمقدار 8% مقارنة مع LEACH و 24% مقارنة مع LEA2C. لم يعتمد الباحث الحساسات المتجاوزة لاختيار قائد العنقود كي لا تستهلك طاقة الحساسات في منطقة معينة قبل منطقة أخرى، ويأمل الباحث بإنجازات أكبر عند تعديل بعد الشروط. سنقوم برسم المخطط التالي اعتماداً على نتائج هذه الدراسة لتبيان أهمية استخدام الشبكات العصبونية في عمل بروتوكولات التحويل لشبكات الحساسات اللاسلكية :



الشكل (10) تحسين زمن حياة شبكة الحساسات اللاسلكية باستخدام الشبكات العصبونية

1.9 كشف الأخطاء والمناعة ضد الأعطال ونقص البيانات

تتعرض شبكة الحساسات كثيراً للأخطاء ونقص البيانات، وهذه الأخطاء قد تكون على مستوى الحساس نفسه أي أنه ينتج بيانات خاطئة، فالحساسات بطبيعتها معرضة للأخطاء البرمجية وأخطاء العتاد بسبب ظروف عملها ومحدوديتها [1]، أو قد تتعرض بياناته السليمة إلى الخطأ أو النقصان أثناء إرسالها بسبب طبيعة الوصلة اللاسلكية المتغيرة وغير المستقره مع الزمن، وبسبب عوامل أخرى كثيرة منها تصادم حزم البيانات أثناء إرسالها، خفوت الإشارة، التداخل، وإرسال البيانات كما هي تضعف وثوقية شبكة الحساسات اللاسلكية، وفي بعض الأحيان قد يكون للخطأ البسيط في شبكة الحساسات نتائج مدمرة، فخطأ في حساس واحد مستخدم لإطلاق مكوك الفضاء ديسكفري تم اكتشافه عن طريق الاستقصاء الشخصي فأدى إلى تأجيل إطلاقه [12].

يمكن كشف الأخطاء وتقادها بمضاعفة عدد الحساسات ولكن ذلك غير مجدٍ نظراً للتكلفة المادية والطاقة المستهلكة الإضافية [12]. استخدم الباحث في البحث [21] الشبكة العصبونية RNN لكشف الخطأ على مستوى الحساس ويتم ذلك بمقارنة خرج الحساس بخرج الشبكة العصبونية، فإذا كان الفرق أكبر من عتبة معينة يكون هنالك خطأ في الحساس. حيث يتم تأمين بيانات الدخل للشبكة اعتماداً على بيانات خرج الشبكة العصبونية والحساسات المجاورة الحالية والسابقة. تكون قيمة خرج نموذج الشبكة العصبونية المقدر من خلال العلاقة :

$$y_i(k) = RNN_i(y_i(k-1), y_i(k-2), \dots, y_i(k-m), y_{ij}(k), y_{ij}(k-1), \dots, y_{ij}(k-n)) + c \quad (6)$$

حيث $y_i(k-m)$: تعبر عن خرج الشبكة السابق، $y_{ij}(k-n)$: تعبر عن خرج الحساسات المجاورة، c : ثابت. فإذا كانت قيمة الخرج أكبر من عتبة معينة فهذه إشارة إلى أن هنالك خطأ في قراءة الحساس عند العينة المقابلة $RNN_i(k)_{Y_i(k)} > \eta$ وبذلك يمكننا اتخاذ الإجراء المناسب كعزل هذا الحساس ومنعه من الإرسال.

وفي البحث [2] يستدل الباحث على الحساسات المعطوبة عن طريق رقم التصنيف الناتج عن تجميع البيانات. استخدم الباحث في البحث [1] شبكة HopField من أجل اختبار مناعة الشبكة للأخطاء، وحصل على نسبة تعرف جيدة. ولزيادة زمن حياة الشبكة قام بتجميع البيانات الناتجة على خرج الحساسات باستخدام حساس يشغل شبكة SOM بحيث يتم إنقاص حجم بيانات الدخل. و قام الباحث في البحث [12] باستخدام الشبكة العصبونية fuzzyART لتصنيف البيانات واستخدم خوارزمية لتعويض النقص في البيانات مكانياً وزمنياً، مكانياً اعتماداً على بيانات الحساسات المجاورة والتابعة لنفس العقود باعتبار أن الحساسات تكون قريبة بعضها من بعض وقراءاتها متقاربة. وزمنياً اعتماداً على القراءات السابقة للحساس، وذلك لزيادة وثوقية الشبكة، وقام الباحث أيضاً بمقارنة طريقته بطرق أخرى لتعويض نقص البيانات، وأثبت أن طريقته أفضل لتطبيقها على شبكة الحساسات. وفي البحث [10] قام الباحث أيضاً باختبار الخوارزمية SIR ومقارنتها مع الخوارزميتين Directed Diffusion DD, Energy Aware Routing EAR حيث زمن التأخير ومقدار الطاقة المصروفة في عدة حالات منها : عندما لا يكون هنالك إخفاق في الحساسات، وعندما تخفق 20% - 40% من مجموع الحساسات، وتوصل الباحث إلى نتائج مهمة حيث كان هنالك تحسين ملموس في زمن التأخير استهلاك الطاقة في الحالات التي يزداد فيها إخفاق العقد نتيجة خلل في الطاقة أو زيادة الضجيج، أو عند زيادة عدد العقد مقارنة بالخوارزميات الأخرى.

1.10 لاستخلاص معلومات صحية عن حالة المرضى

من التطبيقات المهمة لشبكات الحساسات اللاسلكية المتنقلة ونشر حساسات في جسم المرضى تقيس درجة حرارتهم وضغط الدم وحتى تحليل حركتهم وأماكن تواجدهم ثم تعالج هذه البيانات لمعرفة مستوى صحة المريض. يتم حديثاً استخدام الشبكات العصبونية وخصوصاً شبكة SOM لهذا الغرض لاستخلاص المعلومات وتعمل هذه الشبكات دون تدخل المراقب وتتعلم تلقائياً من البيانات الجديدة وهي بذلك تكون ديناميكية، لكن الشبكة تفقد هذه الميزة مع مرور الزمن حيث تصبح غير مستقرة وغير قادرة على تعلم أصناف جديدة مع الحفاظ على الأصناف القديمة التي تم تعلمها [22] ، ويتم التغلب على هذه المشكلة باستخدام خوارزمية التجميع k-means كطبقة ثانية لتجميع البيانات على خرج الشبكة العصبونية.

1.11 تحديد موضع الحساسات

إن كثيراً من تطبيقات شبكات الحساسات اللاسلكية تتطلب معرفة دقيقة بموضع الحساسات، وأسهل طريقة لتحديد موضع الحساسات تزويد كل حساس بنظام تحديد الموضع العالمي GPS، إلا أن هذه العملية مكلفة وقد تكون

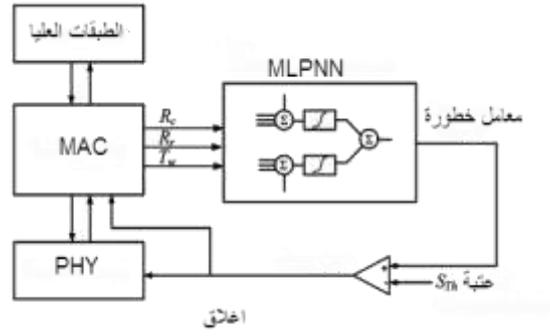
الحساسات موجودة في أماكن لا تكون التغطية فيها جيدة. لقد استخدم الباحثون طرقاً كثيرة لتحديد موضع الحساسات يعتمد أغلبها على شدة الإشارة القادمة من الحساسات المجاورة؛ ومن هذه الطرق Lateration, Nearest Neighbor (KNN), K-Nearest Neighbor (KNN) و يتم حديثاً استخدام الشبكات العصبونية ANN. في البحث [13] قام الباحث بمقارنة ثلاث طرق لتحديد موقع الحساسات، KNN, ANN, Lateration اعتماداً على مستوى قوة الإشارة المستقبلية RSSI ووجد تفوق استخدام الشبكة العصبونية على الطريقتين السابقتين. وفي البحث [6] قام الباحث بوضع بضعة حساسات في بعض نقط التقاطع لشبكة حساسات لاسلكية وقام بتدريبها للتعرف على موضعها اعتماداً على البعد عن حساسات محددة الموضع مسبقاً Anchor Nodes باستخدام نماذج الشبكة العصبونية الموجودة في برنامج الماتلاب، ثم وضعها الباحث عشوائياً في الشبكة، وأظهرت النتائج دقة تحديد موضع مقبولة يمكن تحسينها بالاختيار المناسب للحساسات محددة الموضع.

1.12 تعقب الأهداف

تعد عملية تعقب الأهداف من التطبيقات المهمة لشبكة الحساسات اللاسلكية والمهم في هذه العملية هو الموازنة بين الدقة في التعقب ومقدار استهلاك الطاقة. يؤمن استخدام الشبكات العصبونية لتوقع حركة الهدف اعتماداً على حركاته السابقة الشرطين السابقين، وتكون هذه الطريقة مفيدة خاصة في الشبكات اللاسلكية التي لا تؤمن تغطية كاملة للمنطقة المراقبة، وبما أن حركة الأجسام تكون غالباً غير محددة لذا يجب على الشبكة توقع نموذج تقريبي للحركة من أجل تفعيل أقل عدد من الحساسات بحيث يمكن تتبع الحركة. في البحث [23] استخدم الباحث شبكة (MLPNN) لتوقع حركة الهدف في شبكة الحساسات اللاسلكية البصرية وتحديد الحساسات الواجب تفعيلها لتأمين التغطية المناسبة لحركة الهدف وتوفير استهلاك الطاقة في الشبكة، حيث تقوم الحساسات التي تحسنت للهدف بإرسال موقع الهدف إلى العقدة المركزية المجهزة بمصدر طاقة كبير مقارنة بغيرها من الحساسات. وبعد فترة زمنية T يكون الحساس المركزي قد حصل على مواقع حركة الحساس في الزمن 0-T، تستخدم هذه البيانات لتدريب الشبكة العصبونية لكشف المواقع اللاحقة للهدف ومن ثم حركته في الزمن T+Z. ولتحديد دقة طريقة استخدام الشبكة العصبونية في تحديد موقع الهدف لجسم متحرك بشكل عشوائي بسرعة 5 م/ثا تمت مقارنة المسار المتوقع مع المسار الحقيقي، وأظهرت المحاكاة دقة في تحديد حركة الهدف.

1.13 حماية الشبكة في بروتوكولات التحكم بوسط النقل

تتعرض شبكة الحساسات إلى هجمات عديدة هدفها تعطيل عمل الشبكة ومن أهمها DOS Attack الذي يعمل عن طريق إرسال حزم بيانات تطغى أو تتصادم مع حزم بيانات الشبكة وتمنعها من الوصول إلى هدفها، أو إغراق الشبكة برسائل لا حاجة لها؛ الأمر الذي يعطل عمل الشبكة ويستنزف طاقتها. في البحث [24] يعتمد بروتوكول التحكم بوسط النقل MAC على الشبكة العصبونية MLP في تأمين الحماية لعمل الشبكة ضد تعطيل الخدمة من خلال إغراق الشبكة بالطلبات، ويبين الشكل (11) طريقة حساب معامل الخطورة لحماية شبكة الحساسات باستخدام شبكة MLPP.



الشكل (11) احتساب معامل الخطورة لحماية شبكة الحساسات باستخدام شبكة MLPNN

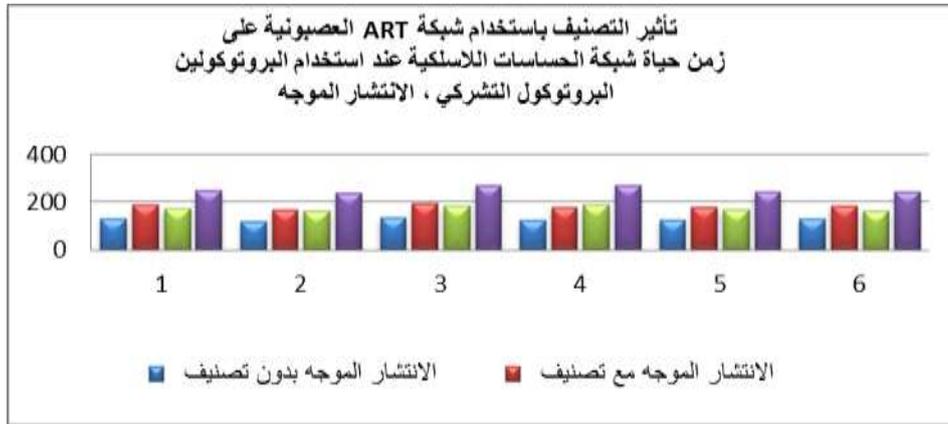
يتم العمل عن طريق المراقبة والكشف للتغيرات في بارامترات عمل الشبكة أثناء الهجوم وتوقيف الطبقة الفيزيائية للحساس المستهدف عندما يزيد خرج الشبكة العصبونية الذي يقوم باحتساب معامل الخطورة لكشف الهجوم، وبهذه الطريقة يتم تفادي الهجوم والحفاظ على طاقة شبكة الحساسات اللاسلكية.

1.14 معالجة البيانات ضمن الشبكة

ترمي الحساسات عادة بشكل عشوائي في المنطقة المراد مراقبتها ويسبب صغر حجمها ومدى تغطيتها يرمى عدد كبير من تلك الحساسات، وغالبا ما يتحسس الحساس لأكثر من بارامتر من بارامترات البيئة الموضوع ضمنها، وتكون الحساسات قريبة فيما بينها الأمر الذي يجعل حجم البيانات كبير، وكثير منها مكرر، وبما أن إرسال هذه البيانات إلى المحطة الرئيسية هو أكثر العمليات كلفة من حيث استهلاك الطاقة في الحساسات [3] فإن إرسالها كما هي دون معالجة سوف يرهق الشبكة ويهدر طاقتها بشكل كبير، لذلك فهناك ضرورة ملحة لمعالجة هذه البيانات ضمن الشبكة على أن يكون موضوع استهلاك الطاقة من العوامل الرئيسية التي يجب أخذها بعين الاعتبار بحيث تكون الطاقة المصروفة على معالجة البيانات أقل من الطاقة التي تم توفيرها نتيجة قيامنا بالمعالجة. هنالك طريقتان لمعالجة بيانات الحساسات هما المعالجة المركزية والمعالجة الموزعة، ترسل في المعالجة المركزية جميع الحساسات بياناتها إلى الحساس المركزي وهذا يرهق الشبكة ويستهلك قسماً كبيراً من الطاقة، لذلك هنالك حاجة لمعالجة هذه البيانات لاستخلاص المفيد ودمجها لإلغاء التكرار بحيث توفر في الطاقة المصروفة، ونحسن أداء الشبكة وقابليتها للتوسع وهذا ما تهدف إليه المعالجة الموزعة. إن استخدام الشبكات العصبونية في معالجة البيانات "تصنيف، تجميع، دمج" يمكن أن يشكل بديلاً عن الطرق التقليدية [1] ويحقق الفائدة المرجوة منه عندما تكون كلفة استخدامه في شبكة الحساسات من حيث كمية الحسابات والطاقة المصروفة أقل من عدم استخدامه، إلا في التطبيقات التي يكون فيها استخدام الشبكات العصبونية يؤمن خصائص فريدة لا يمكن الحصول عليها بطرق أخرى.

تعتمد فكرة الحاجة لتصنيف البيانات في شبكة الحساسات اللاسلكية على : عند تصنيف بيانات كل حساس في الشبكة أو تصنيف بيانات حساس يعمل كقائد مجموعة لمجموعة حساسات أخرى يمكننا الاكتفاء بإرسال رقم الصنف فقط، وهذا يوفر بشكل كبير في الطاقة المصروفة على إرسال البيانات ويزيد زمن حياة الشبكة. وتعد شبكات الحساسات اللاسلكية المقسمة إلى عناوين Clustered WSN والتي يكون فيها لكل عنقود من الحساسات قائد عنقود يقوم باستقبال بياناتها ويعالجها ثم يقوم بإرسالها إلى المحطة القائمة مباشرة أو عبر قادة عناوين آخرين البيئة المناسبة لعمل الشبكة العصبونية من أجل توفير استهلاك الطاقة، ويمكن أن تتم هذه العملية بشكل هرمي بحيث يكون لكل مجموعة

من قادة العناقد قائد أيضاً ونحصل بذلك على توفير إضافي في الطاقة المستهلكة. تم اعتماد هذه الهيكلية من قبل الباحث في البحث [2] كهيكلية مناسبة لعمل الشبكة العصبونية ART, FuzzyArt. فعلمية تصنيف البيانات تساعد على ضغطها وإنقاص حجمها [25] مما يوفر في الطاقة اللازمة لعملية تحويل هذه البيانات ضمن شبكة الحساسات. ولتبيان أهمية استخدام الشبكات العصبونية في تصنيف البيانات، سنقوم بمقارنة عمل بروتوكولي التحويل التشاركي والانتشار الموجه قبل استخدام الشبكة العصبونية وبعده وذلك لشبكة مكونة من 50 حساساً مع تغيير طوبولوجيا الشبكة في كل تجربة. يوضح الشكل (12) زيادة زمن حياة شبكة الحساسات بشكل ملحوظ بعد استخدام التصنيف وخصوصاً عند استخدام طريقة التحويل التشاركي. عندما تتحسس شبكة الحساسات اللاسلكية لأنواع مختلفة من البيانات هناك حاجة لدمج تلك البيانات، مما يساعد في تقليص حجمها وفي التعرف عليها ولو تعرضت للضجيج وذلك نحقق مزيداً من الدقة في شبكة الحساسات ونوفر في الطاقة [19]. من التقنيات المعروفة في دمج البيانات يوجد Kalman filtering, Bayesian, fuzzy logic وكذلك الشبكات العصبونية [8]، ويمكن تصنيف عملية دمج البيانات بحسب العلاقة بين مصادر البيانات إلى دمج البيانات المكمل، دمج البيانات الفائضة، دمج بيانات تعاوني.



الشكل (12) تأثير استخدام التصنيف باستخدام الشبكة العصبونية على زمن حياة شبكة الحساسات اللاسلكية

النتائج والمناقشة:

قمنا باقتراح تطبيق شبكات الحساسات اللاسلكية في بعض الحالات لمعالجة المعطيات باستخدام الشبكات العصبونية. يرفع تطبيق هذه التقنية على مستوى عقد التحسس من كلفة الشبكة بشكل كبير مع أنه يحقق وفراً كبيراً في استهلاك الطاقة وإطالة مديدة لعمر الشبكة. وهو ما تم اقتراحه في العديد من الأبحاث المذكورة. يعتمد اقتراحنا على تطبيق المعالجة في العقد الفائدة فقط وليس على مستوى عقد التحسس. حيث تقوم الشبكة المقترحة بجمع معطيات عن ثلاثة بارامترات مرتبطة بعضها ببعض. بحيث يعطي تقييم هذه المعطيات قراراً حول حدوث عملية ما، مثلاً حدوث حريق في مكان ما وفي هذه الحالة تكون القيم المعنية معبرة عن بارامترات مثل الحرارة والرطوبة و كمية غاز ثاني أوكسيد الكربون، وهي ما عبرنا عنها بـ A و B و C.

يفترض السيناريو المقترح استخدام العقدة، وأن ترتبط كل مجموعة من عقد التحسس بقائد العقدة كما هو موضح في الشكل (13). يقوم قائد العقدة باستقبال معطيات من n عقدة تحسسية. وقد افترضنا أن كل عقدة تحسس ثلاث قيم فيزيائية، تشكل مؤشرات فيزيائية حول القيم التي تقوم الشبكة مراقبتها. أي إن كل عقدة تحسسية N_i ترسل

لقائد العقود ثلاث قيم حول كل بارامتر يتم تحسسه. أي ما مجموعه 9 قيم، هي Amin وهي القيمة الدنيا التي يتم الحصول عليها لهذا البارامتر خلال فترة زمنية محددة (ساعة، أو يوم، أو عدة ساعات متصلة من اليوم)، Amax وهي القيمة العظمى التي يتم الحصول عليها لهذا البارامتر خلال الفترة الزمنية المحددة نفسها و Aavg وهي القيمة المتوسطة التي يتم الحصول عليها لهذا البارامتر خلال فترة زمنية تحدد حسب أهمية العملية التي تتم مراقبتها كأن تكون دقيقة أو أجزاء منها أو ساعة أو أجزاء منها.

والشيء نفسه بالنسبة للبارامترين الآخرين أي للقيم Bavg، Bmax، Bmin وكذلك Cavg، Cmax، Cmin يتم حساب جميع هذه القيم في قائد العقود وإرسال رزم معطيات بنتائج الحساب إلى نقطة التجميع Sink. باعتماد النموذج العصبوني Feed Forward Neural Network FFNN الشكل (14)، فقد اقترحنا التعبير عن الخرج بالعلاقة الآتية :

$$S = W_{A1} * A_{max} + W_{A2} * A_{min} + W_{A3} * A_{avg} + W_{B1} * B_{max} + W_{B2} * B_{min} + W_{B3} * B_{avg} + W_{C1} * C_{max} + W_{C2} * C_{min} + W_{C3} * C_{avg} \quad (7)$$

حيث إن W_{A1} و W_{A2} و W_{A3} هي الأوزان المتعلقة بالبارامتر A

وإن W_{B1} و W_{B2} و W_{B3} هي الأوزان المتعلقة بالبارامتر B

حيث إن W_{C1} و W_{C2} و W_{C3} هي الأوزان المتعلقة بالبارامتر C

إن اقتراح قيم هذه الأوزان يتم بعد التدريب من قبل عقدة الإدارة Management Node بما يلائم عمل الشبكة. حين يستقبل قائد التجمع الرزم من عقد التحسس يقوم بمعالجتها وفقاً للأوزان المقترحة واستخلاص ما يمكن تسميته مؤشر الخطر ويرسله ضمن رزمة إلى عقدة التجميع.

استخدمنا محاكي الشبكة ns2 حيث تم اعتماد سيناريوهات تفترض توزيع الحساسات ضمن مناطق مربعة مختلفة المساحات وتختلف من حيث عدد الحساسات المنشورة فيها. وفقاً للجدول الآتي:

الجدول (1) سيناريوهات توزيع الحساسات ضمن الشبكة

عدد الحساسات	مساحة المنطقة	السيناريو
50	0.25 km ²	الأول
50	0.5 km ²	الثاني
100	0.5 km ²	الثالث
100	0.75 km ²	الرابع
150	0.75 km ²	الخامس
150	1.00 km ²	السادس
200	1.00 km ²	السابع

وتغطي هذه السيناريوهات حالات عملية مشابهة لواقع نشر الحساسات بشكل محدد في كثير من التطبيقات من حيث البعد بين الحساسات ومن حيث كثافتها، مثل مراقبة حرائق الغابات، ومراقبة الانبعاثات الغازية، وفي التطبيقات الأمنية وغيرها.

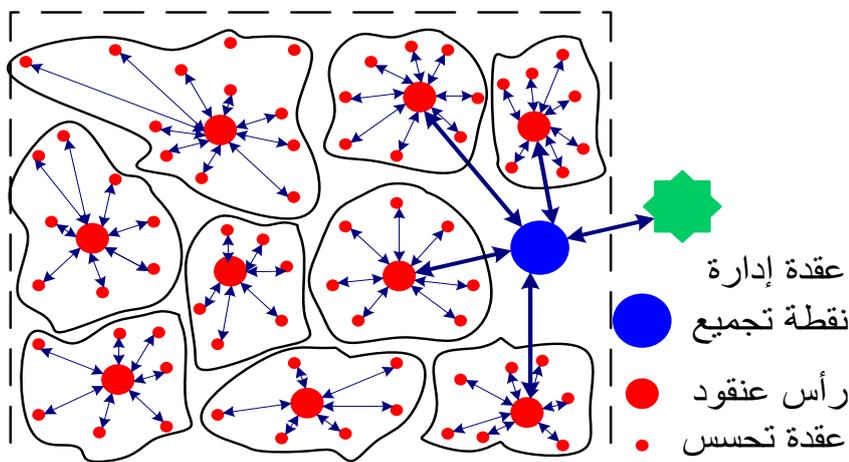
تم تنفيذ كل المحاكاة من أجل الحالتين: حالة عدم تطبيق تقنية الشبكات العصبونية وحالة تطبيق الشبكات العصبونية. افترضنا أن المحاكاة استمرت في كل حالة لمدة 300 ثانية وأن كل عقدة تحسّس تولد رزمة واحدة كل ثلاث ثوانٍ. وهذه الفرضية مناسبة لأغراض التحسس في تطبيقات مثل كشف حرائق الغابات [26,27,28].

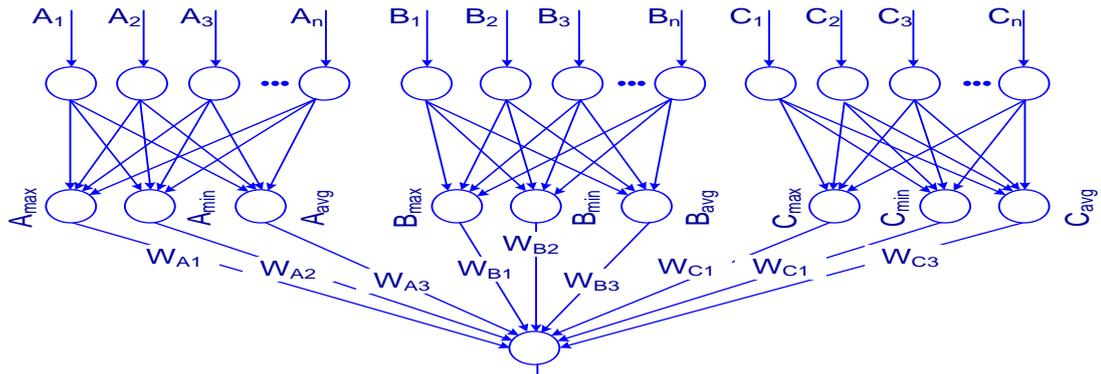
تم الحصول على النتائج من أجل 3 تشكيلات عنقودية مختلفة في كل حالة وأخذ المتوسط الحسابي لعدد الرزم التي يجري إرسالها بين عقد التحسس وبين قائد التجمع من جهة kn ، وبين قائد التجمع ونقطة التجميع Sink وهي kc من جهة أخرى.

حساب النسبة بين العدد الوسطي للرزم في الحالة الثانية kc والعدد الوسطي للرزم في الحالة الأولى kn . حيث إن استهلاك الطاقة في إرسال الرزم واستقبالها كما في الشكل (16) يشكل النسبة الأعلى من استهلاك الطاقة في الحساسات ومن ثم الطاقة الكلية للشبكة.

ثم مقارنة النسبة التي حصلنا عليها والتي تعطي مؤشراً واضحاً حول استهلاك الطاقة في حالة استخدام الشبكات العصبونية وفي حالة عدم استخدام الشبكات العصبونية وذلك من خلال رسم المنحني الذي يمثل الحالتين من أجل السيناريوهات السبعة المقترحة.

وكذلك المنحني الذي يمثل نسبة حمل المعطيات في حالتي استخدام الشبكات العصبونية وعدم استخدامها. وقد استنتجنا أن استخدام الشبكات العصبونية يخفض عدد الرزم المرسلّة ومن ثم استهلاك الطاقة بشكل كبير عما هو في حالة عدم استخدامها وهذا واضح في الشكل (15,16). كما أن الشبكات العصبونية مناسبة للتطبيقات من أجل المساحات والكثافات المقترحة وهذه التطبيقات كثيرة في الحياة العملية مثل مراقبة حرائق الغابات ومراقبة الانبعاثات الغازية وفي التطبيقات الأمنية وغيرها.

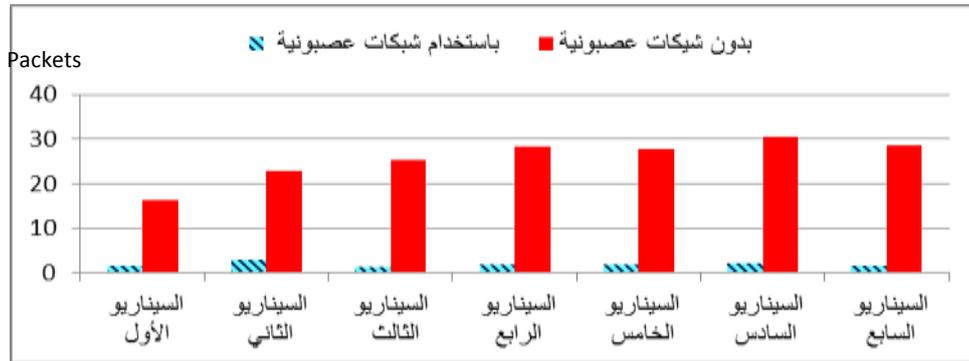




$$S = W_{A1} * A_{max} + W_{A2} * A_{min} + W_{A3} * A_{avg} + W_{B1} * B_{max} + W_{B2} * B_{min} + W_{B3} * B_{avg} + W_{C1} * C_{max} + W_{C2} * C_{min} + W_{C3} * C_{avg}$$

الشكل (14) الشبكة العصبونية المقترحة

يقوم قائد العنقود باستقبال الرزم التي تحوي قيم البارامترات A و B و C من كل عقدة من مجموع العقد المشكلة للعنقود وهو n عقدة، حيث إن $1 \leq i \leq n$.



الشكل (15) مقارنة حمل المعطيات في حالتي استخدام الشبكات العصبونية وعدم استخدامها



الشكل (16) مقارنة نقل الرزم في حالتي استخدام الشبكات العصبونية وعدم استخدامها كنسبة مئوية.

1.15 مقارنة نماذج الشبكة العصبونية

المميزات	الشبكة العصبونية
	ART - لا تحد عدد العناقيد التي سيتم تجميع البيانات من خلالها - التعلم التلقائي - السرعة في التعلم ودون مراقبة خارجية - القدرة على التعلم والتصنيف في نفس الوقت.
	- حلها لمشكلة المرونة والاستقرار ، حيث يمكن للشبكة الاستمرار في تعلم الأصناف الجديدة دون نسيان الأصناف القديمة، وهي بذلك تتفوق على شبكة SOM التي تحتاج إلى طرق مكتملة لكي تحل هذه المشكلة - القدرة على التحكم بعدد الأصناف - القدرة على كشف البيانات المحملة بالضجيج - إمكانية التحكم بعدد العناقيد التي يتم تصنيف البيانات إليها.
	HopField - القدرة على تخزين النماذج عن طريق العلاقات فيما بينها- القدرة على تصحيح أخطاء النماذج
	SOM - تعمل دون تدخل المستخدم وتصنف البيانات بشكل جيد - الحاجة لفترة تعلم طويلة نسبياً قبل البدء بالعمل - العدد المحدد مسبقاً للأصناف التي يمكن تصنيف البيانات وفقاً لها.
	- بعد فترة طويلة من العمل لا تمتلك القدرة على الحفاظ على النماذج القديمة مع تعلم أصناف جديد - تعمل ببطء وبشكل غير مستقر عند أحجام بيانات كبيرة.

1.16 مقارنة الدراسات حول استخدام الشبكات العصبونية في شبكات الحساسات اللاسلكية

البحث	الغاية من استخدام الشبكة العصبونية	بارامترات الدخل	نموذج	التطبيق الفعلي
[1]	- إثبات التشابه وإمكانية استخدام الشبكات العصبونية في شبكات الحساسات اللاسلكية - التعرف واستكمال نماذج البيانات الناقصة- زيادة زمن حياة الشبكة	الحرارة،الرطوبة،شدة الإضاءة	SOM HN	تم التطبيق العملي للشبكة HN حساسات Telos
[2]	- تجميع البيانات لحفظ الطاقة - المناعة من أخطاء الحساسات	شدة الإضاءة، الصوت ، التسارع ، الحرارة ، الضغط	ART1 Fuzzy ART	المحاكاة اعتماداً على بيانات عملية
[5]	- كشف خطأ قراءة أو عطب الحساسات ومنعها من الإرسال.	اعتماداً على بيانات الحساسات المجاورة.	غير محدد	استخدام المحاكاة
[6]	تحديد موضع حساسات منشورة عشوائياً اعتماداً على عقد مرجعية.	موقع العقد المحددة الموضع مسبقاً.	MPL	Matlab
[9]	- إثبات إمكانية التنفيذ الفعلي للشبكة العصبونية باستخدام FPGA	الحرارة،الرطوبة،شدة الإضاءة	MLP	تم التنفيذ الفعلي
[10]	- حساب جودة الوصلة اللاسلكية باستخدام الشبكة العصبونية لاختيار المسار المناسب للتحويل - دراسة تأثير العطل المادي لجزء من الحساسات على عمل بروتوكول التحويل في الشبكة.	زمن التأخير معدل الخطأ زمن التشغيل معدل النقل	SOM	تم التطبيق العملي على حساسين وتم استخدام المحاكاة OLIMPO Matlab

[11]	- كشف الانحراف عن الوضع الطبيعي لبيئة العمل.	شدة الإضاءة	Fuzzy Art	تم التطبيق العملي باستخدام Tmote Sky
[12]	- زيادة دقة شبكة الحساسات اللاسلكية عن طريق تقدير قيمة البيانات الناقصة وتكملة نموذج البيانات بالاستعانة بطبيعة بيانات شبكة الحساسات المكررة زمنياً ومكانياً.	شدة الإضاءة الحرارة	Fuzzy ART	تم التطبيق العملي باستخدام Crossbow mote
[15]	- إدارة وتوفير استهلاك الطاقة - اختيار مسار التحويل والتنبؤ بالأماكن التي يتم فيها استهلاك طاقة بشكل كبير Hotspot	- الموقع - عدد الحساسات في الجوار - عدد الحساسات التي يقع الحساس في مسارها	غير محدد	استخدم المحاكاة
[16]	- تبيان فائدة استخدام الشبكات العصبونية في شبكات الحساسات عند تعديل أو إعادة برمجة الحساسات.	بيانات من تطبيقين: تقدير صحة المرضى، تصنيع النبيذ.	FFN C_MAN TEC	Cooja simulator
[18]	- اختيار قائد العنقود - زيادة زمن حياة الشبكة	موقع الحساسات ضمن الشبكة وكمية الطاقة المتوفرة	SOM	محاكاة باستخدام Matlab
[20]	- اختيار قائد العنقود بمساعدة الشبكة العصبونية بحيث تتحقق التغطية والاتصال المناسبة في الشبكة - توفير استهلاك الطاقة عند تحويل البيانات لزيادة زمن حياة شبكة الحساسات	اعتماداً على جودة الاتصال ومقدار استهلاك الطاقة أثناء تحويل البيانات الناجح بين الحساسات	FFNN	محاكاة
[21]	- تحديد موضع الحساسات المتحركة	قياس شدة الإشارة المستقبلية	FFNN	Matlab
[24]	تعقب الأهداف	اعتماد على الحركات السابقة	MLPNN	محاكاة
[25]	حماية الشبكة من الهجوم	معدل التصادم، معدل طلب الرزم، معدل انتظار الرزم	MLP	محاكاة

الاستنتاجات والتوصيات :

- من النتائج التي حصلنا عليها، من المحاكاة ومن الأبحاث التي قمنا بدراستها، نلاحظ أهمية استخدام الشبكات العصبونية في شبكات الحساسات اللاسلكية وتطبيقاتها المتعددة التي يمكنها الاستفادة من قدرة الشبكة العصبونية على التصنيف السريع والتنبؤ ونمذجة التوابع .

- استخدام الشبكة العصبونية في معالجة بيانات شبكة الحساسات اللاسلكية أدى إلى تقليل عدد الرزم المتبادلة ضمن الشبكة، وبما أن عملية تبادل البيانات تستهلك القسم الأكبر من الطاقة فنكون بذلك قد وفرنا قسطاً كبيراً من الطاقة وزدنا زمن حياة الشبكة.

- لسرعة معالجة البيانات ضمن الشبكة العصبونية أهمية كبيرة في التطبيقات التي تحتاج استجابةً بالزمن الحقيقي.

- نحن بحاجة لدراسات وأبحاث نقوم فيها بدراسة آلية التنفيذ المادي للشبكة العصبونية وكلفة تنفيذها ومدى استهلاكها للطاقة أثناء التدريب وأثناء معالجة البيانات. ومن المتوقع تزايد الاهتمام بهذا الموضوع وخصوصاً بعد انتشار الحساسات الداعمة للوسائط المتعددة نظراً للقدرة العالية للشبكات العصبونية في التعامل مع الفيديو والصور.

المراجع:

1. FRANK,O.;PETRI,M.*Neural wireless sensor networks*. Systems and Networks Communications, ICSNC'06,International Conference on IEEE, 2006.
2. KULAKOV,A.;DAVCEV,D. *Data mining in wireless sensor networks based on artificial neural-networks algorithms*. in proc workshop data mining sens,newport beach, 2005.
3. GUPTA,V.;PANDEY,R.*Data fusion and topology control in wireless sensor networks*. wseas transactions on signal processing,issue 4, volume 4, april 2008.
4. KAUR,J; RAI,M.K.DR.*Dynamic clustering in wireless sensor network using neural network*.international journal for advance research in engineering and technology, volume 1, issue ii, 2013.
5. BAHANFAR,S.;KOUSHA,H.;DAROUGARAN,L.*Neural networks for error detection and data aggregation in wireless sensor network*.ijcsi international journal of computer science issuesvol, 8,issue 5, no 3,september 2011.
6. BHARDWAJ,S .*ANN for node localization in wireless sensor network* .international journal of advanced research in electrical, electronics and instrumentation engineering,vol. 2, issue 5, may 2013.
7. JABBARI,A.; JEDERMANN,R.; MUTHURAMAN,R.; LANG,W. *Application of neurocomputing for data approximation and classification in wireless sensor networks*. sensors 2009,3056-3077.
8. KASABOV,N.K.*Foundations of neural networks, fuzzy systems, and knowledge engineering*. the mit press cambridge,massachusetts london, 1998.
9. JAMEL,TH.M.;BAN M.KHAMMAS,B.M.;ZIBAR,M.K.*FPGA based neural wireless sensor network*. the 13th international arab conference on information technology, acit Dec.10-13,2012.
10. BARBANCHO,J.; LEON,C.; MOLINA, F.J.BARBANCHO, A.*Using artificial intelligence in routing schemes for wireless networks*. computer communications , Volume 30 Issue 14-15,2007,2802-2811 .
11. WALCHLI,M.; BRAUN, T.*Efficient signal processing and anomaly detection in wireless sensor networks* .volume 5484 of lecture notes in computer science.springer, 2009,81-86.
12. MOUSTAPHA,A.I.;SELMIC,R.R.*Wireless sensor network modeling using modified recurrent neural networks: application to fault detection* .IEEE transactions on instrumentation and measurement, vol. 57, no. 5, may 2008.
13. MACHADO,L.;LARRAT ,M.;MONTEIRO,D.*Performance evaluation of lateration, knn and artificial neural networks applied to real indoor localization in wsn*. the second international conference on communications, 20131521-1507.

14. HEINZELMAN, W.B.; CHANDRAKASAN, A.; BALAKRIS, H. *Application-specific protocol architecture for wireless microsensor networks*. IEEE transactions on wireless communications, 2002, 660 - 670.
15. HOSSEINGHOLIZADEH, A.; ABHARI, A. *A neural network approach for wireless sensor network power management*. in the proceedings of 2nd international workshop on dependable network computing and mobile systems, usa, september 2009.
16. MUNOZ, D.U.; CARMONA, E.C.; CONTRERAS, J.L.S.; FRANCO, L.; TORRES, L.M.L.; A RAGONES, J.M.J. *Energy-efficient reprogramming in wsn using constructive neural networks*. international journal of innovative computing, volume 8, november 2012 .
17. HOLENDERSKI, M.; LUKKIEN, J.; KHONG, T.C. Trade-offs in the distribution of neural networks in a wireless sensor network. International Conference on Intelligent Sensors, Sensor Networks and Information Processing, Vol. 5, Melbourne Australia, 2005.
18. ENAMI, N.; MOGHADAM, R.A. *Energy based clustering self organizing map protocol for extending wireless sensor networks lifetime and coverage*. canadian journal on multimedia and wireless networks, vol. 1, no. 4. , august 2010.
19. NIMBALKAR, J.K. *Use of neural network in wsns*. international journal of advancement in electronics and computer engineering (ijaece). volume 1, issue 3, june 2012, 93-98.
20. KUMAR, N.; KUMAR, M.; PATEL, R.B. *Coverage and connectivity aware neural network based energy efficient routing in wireless sensor networks* . journal on applications of graph theory in wireless ad hoc networks and sensor networks , vol.2, no.1, march 2010.
21. BARRON, J.W.; MOUSTAPHA, A.I.; SELMIC, R.R. *Real-time implementation of fault detection in wireless sensor networks using neural networks*. fifth international conference on, information: new generations, itng 2008, 378 – 383.
22. KORELI, B.T.; KOO, S.G.M.A. *Survey on context-aware sensing for body sensor networks* . wireless sensor network Vol. 2 No. 8, 2010, 571-583.
23. SABOKROU, M.; FATHY, M.; HOSENI, M. *Intelligent target tracking in wireless visual sensor networks* .computer and knowledge engineering, IEEE , Mashhad 18-19 Oct , 2012, 227 - 231 .
24. KULKARNI, R.V.; VENAYAGAMOORTHY, G., K. *Neural network based secure media access control protocol for wireless sensor networks*. proceedings of international joint conference on neural networks, usa, june 14-19, 2009.
25. PATRIKAR, R.M.; AKOJWAR, S.G. *Neural Network Based Classification Techniques For Wireless Sensor Network with Cooperative Routing*. 12th WSEAS International Conference on COMMUNICATIONS, Heraklion, Greece, July 23-25, 2008.
26. FERNANDES, A.; UTKIN, A.; LAVROV, A.; VILAR, R. *Development of Neural Network Committee Machines for Forest Fire Detection Using Lidar*. Pattern Recognition, vol. 37, no. 10, 2004, 2039-2047.
27. HONG, B.; PRASANNA, V. K. *Optimizing a Class of In-network Processing Applications in Networked Sensor Systems*. in Proceedings of IEEE International Conference on Mobile Ad-hoc and Sensor Systems, October 2004, 154-136.
28. YOUNIS, O. ; FAHMY, S. *Distributed Clustering in Ad-hoc Sensor Networks: A Hybrid, Energy-Efficient Approach*. in Proceedings of IEEE INFOCOM, vol 1, 7-11 March 2004.