



الجمهورية العربية السورية

جامعة دمشق

كلية الهندسة الميكانيكية و الكهربائية

قسم الهندسة الطبية

استخدام التشخيص المحوسب في تقييم نتائج اختبار وظائف الرئة للمساعدة في تشخيص أمراض الجهاز التنفسي

Using of Computerized Diagnosis in evaluation of Pulmonary Function Test's Results to help in Diagnosis of Respiratory Diseases

رسالة أعدت لنيل درجة الماجستير في الهندسة الطبية

إعداد

م. أحمد عبد الستار المظلوم

الدكتور المشرف

د.م. عبد الرزاق الحناوي

الدكتور المشارك

د. ميساء أبو القاسم

العام الدراسي

2013-2012

**استخدام التشخيص المحوسب في تقييم نتائج اختبار وظائف الرئة للمساعدة في
تشخيص أمراض الجهاز التنفسي**

**Using of Computerized Diagnosis in evaluation of Pulmonary Function
Test's Results to help in Diagnosis of Respiratory Diseases**

أعضاء لجنة الحكم لرسالة الماجستير في قسم الهندسة الطبية التي أعدها الطالب أحمد المظلوم بعنوان:
((استخدام التشخيص المحوسب في تقييم نتائج اختبار وظائف الرئة للمساعدة في تشخيص أمراض
الجهاز التنفسي)) بكلية الهندسة الميكانيكية والكهربائية:

د. عبد الرزاق الحناوي الأستاذ المساعد في قسم الهندسة الطبية كلية الهندسة الميكانيكية والكهربائية
جامعة دمشق الاختصاص: معالجة صور طبية عضواً مشرفاً

د. ممدوح منيف المدرس في قسم الهندسة الطبية كلية الهندسة الميكانيكية والكهربائية
جامعة دمشق الاختصاص: صيانة الأجهزة الطبية عضواً

د. منذر خضور المدرس في قسم الهندسة الطبية كلية الهندسة الميكانيكية والكهربائية
جامعة دمشق الاختصاص: أجهزة طب نووي وأشعة عضواً

قال تعالى :

(سبحانك لا علم لنا إلا ما علمتنا إنك أنت العليم الحكيم)

(ويرفع الله الذين آمنوا والذين أوتوا العلم درجات)

وقال رسول الله صلى الله عليه وسلم :

(من سلك طريقاً يلتمس فيه علماً سهل الله به طريقاً إلى الجنة)

إهداء

إلى من أعتز وأفتخر بهم إلى

أهلنا الكرام

ذوي القلوب الطاهرة الذين أناروا دروبنا وساندونا بكل الدعاء

والمحبة والأمل وكانوا مصدر ثقتنا ونجاحنا وإبداعنا

ونرجو من الله أن يبقوا شعلة تضيء لنا دروبنا وتمدنا بالقوة والإرادة

التي نتغلب بها على مصاعب الحياة.

كما أخص بالإهداء

أخوتي وأخواتي

أصدقائي

زملائي

وطني الحبيب

كلمة شكر

لكل من ساهم في إنجاز هذا المشروع وأرشدنا إلى الدرب السليم والعلم القويم
لذا نقول شكراً لأساتذتنا الكرام في قسم الهندسة الطبية
وأخص بالشكر

الدكتور المهندس

عبد الرزاق الحناوي

والدكتورة

ميساء أبو القاسم

الذين أشرفوا على المشروع ولم يبخلوا علينا بتوجيهاتهم فلهم منا كل الاحترام والتقدير

كما نخص بالشكر في مشفى الأسد الجامعي - شعبة الأمراض الصدرية

الأطباء

غسان غضبان

ابراهيم المصري

نايف جمعان

الذين قدموا لنا كل المعونة والدعم وساهموا في إنجاز هذا المشروع

ملخص البحث

تعد الحاجة المتزايدة لتشخيص دقيق وسريع لأمراض الجهاز التنفسي الدافع الأساسي للعديد من الأطباء والمهندسين لتحسين أساليب مساعدة لتشخيص هذا النوع من الأمراض بهدف تحقيق كشف مبكر والمساعدة في إتخاذ قرار تشخيص صحيح بنسبة خطأ منخفضة قدر الإمكان. تتبع هذه الحاجة من ارتفاع نسبة انتشار هذا النوع من الأمراض في عصر التطور وانتشار المصانع وبخاصة المناطق السكنية وحتى العاملين في هذه المصانع يمكن أن يكونوا أكثر الناس عرضة ومعاناة، علاوة على انتشار عادة التدخين وما تسببه من أمراض مزمنة. إن أحد الطرق المساعدة في تشخيص هذه الأمراض هي تقنيات الذكاء الصناعي ومنها الشبكات العصبونية التي تملك القدرة على التعلم ونقل الخبرة من الطاقم الطبي الخبير بأساليب ذكية تحاكي أساليب التعلم واكتساب الخبرة عند الإنسان، فكما أن الإنسان قادر على التعلم من خلال طرح الأمثلة والتجربة والتدريب كذلك الشبكات العصبونية التي هي نماذج حسابية تحاكي النموذج الأساسي في تكوين الدماغ البشري ألا وهو العصبون.

تعتمد الشبكات العصبونية وبالأخص المستقبلات متعددة الطبقات MLP المستخدمة في هذه الدراسة على أساليب التعليم الموجه الذي يحتاج لإنجاز عملية التعلم والتدريب على عينات (581 عينة) على شكل ثنائيات (دخل - خرج)، وتتكون الشبكة من طبقات هي طبقة الدخل والخرج والطبقات البينية المخفية. كل طبقة من هذه الطبقات تتكون من عدد معين من العصبونات يعتمد في طبقة الدخل على مداخل الشبكة والتي هي قياسات التشخيص الطبي التي تم تحصيلها من اختبار وظائف الرئة مثل FEV1, FVC, FEV1% وفي طبقة الخرج على مخارج الشبكة والتي هي قرار التشخيص أي نوع المرض الذي يقرره الطبيب الخبير سواء حالة طبيعية سليمة Normal أو علة سادة Obstructive أو قاصرة Restrictive أم مختلطة Mixed.

تستخدم الشبكات العصبونية نوع MLP خوارزميات عديدة للربط بين المداخل وقيم الخرج الهدف - تم اختبار العديد منها في هذه الدراسة - ومهمتها الأساسية إيجاد نموذج حسابي لمثل هذه العلاقات المعقدة وغير الخطية ويرجع الفضل في ذلك لكونها عناصر حسابية عالية التوزع وفق أنظمة تفرعية، وبالنتيجة

يجب أن تحقق هذه الخوارزمية نتائج تصنيف للعينات المدخلة ذات دقة تشخيصية طبية عالية حتى نقول أنها نجحت في تمثيل النموذج الحسابي الرابط بين عينات اختبارات وظائف الرئة والقرار التشخيصي المعتمد من قبل الطبيب الخبير، وبالتالي فإن قدرة الشبكة العالية على تعميم عملية التعلم تكسبها إمكانية اتخاذ قرار التشخيص من أجل عينات لم يسبق لها أن تدربت عليها وفق نسبة دقة تصنيف عالية.

بشكل عام كانت دقة التصنيف لجميع خوارزميات الشبكة العصبونية متعددة الطبقات MLP ذات دقة تصنيف تشخيصية تفوق دقة التصنيف لبرنامج تشخيص جهاز اختبار وظائف الرئة المعتمد على معايير التشخيص العالمية والبرمجة التقليدية (IF-THEN)، فقد أعطت الشبكة العصبونية دقة و نوعية وحساسية أكبر من تلك القيم المقاسة بواسطة برنامج الجهاز، كما أعطت متوسط خطأ أقل مما هو في الجهاز.

حققت كل الخوارزميات المستخدمة في البحث نجاح في تصنيف العينات وكان أفضلها خوارزمية Levenberg Marquardt (LM) بفضل سرعة أدائها خلال عملية التدريب من جهة وتقنية التوقف المبكر المزودة بها. أعطت هذه الخوارزمية دقة قدرها 95% بينما بلغت النوعية قيمة قدرها 84%، وبلغت قيمة الحساسية قيمة قدرها 98%، وسجلت قيمة عالية للمساحة تحت منحنيات ROC بلغت قيمة قدرها 96%، وكانت قيمة متوسط الخطأ صغيرة حيث بلغت قيمة هي 0.033.

تبين لدى مقارنة هذا البحث مع الأوراق العلمية المنشورة في هذا المجال أن هذه الدراسة قد استخدمت 12 خوارزمية مختلفة لتدريب الشبكات العصبونية من النوع MLP والتي لم يتم استخدامها من قبل، كما أنها استخدمت عدد من العينات أكبر من ذلك المستخدم في بعض الأوراق العلمية، وقد أعطت الشبكة العصبونية المصممة نتائج تنافسية فاقت تلك النتائج المسجلة في عدد من الأوراق العلمية. أخيراً نذكر بأنه تم اقتراح قياسين جديدين في هذا البحث يستخدمان قيمة مطال فورييه لمخططين في خرج جهاز تقويم الرئة وقد حصلنا على نتائج مشجعة لاستخدامهما كمداخل إضافية للشبكة العصبونية.

تشير النتائج الإيجابية التي حصلنا عليها إلى التفكير بجدوى تحسين دقة التشخيص الآلي في جهاز فحص وظائف الرئة عند الإنسان عن طريق استخدام تقنيات تعتمد على الشبكات العصبونية ومنها المستقبلات متعددة الطبقات MLP.

فهرس المحتويات

3.....	فهرس المحتويات
7.....	فهرس الأشكال
8.....	فهرس الجداول
10.....	مصطلحات البحث
13.....	الفصل الأول: مقدمة الدراسة
14.....	1 - 1 مقدمة عامة
14.....	1 - 2 المشكلة المدروسة
14.....	1 - 3 الفائدة من البحث
15.....	1 - 4 فكرة البحث
16.....	1 - 5 أهداف البحث
17.....	1 - 6 خطة البحث في الفصول اللاحقة
20.....	الفصل الثاني: الدراسات المرجعية
21.....	2 - 1 الدراسات المرجعية السابقة لأعمال مماثلة لمجال البحث المقترح
29.....	2 - 2 وضع البحث المقترح بالنسبة للدراسات السابقة
31.....	الفصل الثالث: الدراسة النظرية: جهاز اختبار وظائف الرئة
32.....	1-3 لمحة عن تشريح وفيزيولوجيا الجهاز التنفسي Anatomy & Physiology
35.....	2-3 جهاز اختبار وظائف الرئة (PFT) Pulmonary Function Test
38.....	3-3 أمراض الرئة والعلاقة مع قياسات اختبار جهاز وظائف الرئة PFT
38.....	1-3-3 مقدمة عن أمراض الرئة والعوامل المسببة
39.....	2-3-3 العلاقة بين قياسات مخطط التنفس وأمراض الرئة
41.....	4-3 معايير التشخيص العالمية لأمراض الجهاز التنفسي ETS/ERS

5-3	صور مخططات اختبار FVC المستحصل بجهاز PFT وأمثلة مرضية.....	44
	الفصل الرابع: الدراسة النظرية: الشبكات العصبونية وتطبيقاتها.....	49
1-4	أساليب التشخيص المحوسب الطبي Medical Computerized Diagnosis.....	50
1-1-4	الأنظمة الخبيرة Expert Systems.....	50
2-1-4	أساليب الذكاء الصناعي (AI) Artificial Intelligence.....	51
3-1-4	الشبكات العصبونية الصناعية (ANN) Artificial Neural Networks.....	52
1-3-1-4	مقدمة عامة عن الشبكات العصبونية.....	52
2-3-1-4	مميزات ومساوئ استخدام الشبكات العصبونية.....	52
3-3-1-4	أسلوب التعلم في الشبكات العصبونية.....	53
4-3-1-4	أنواع الشبكات العصبونية.....	58
5-3-1-4	الوحدة الأساسية في تكوين الشبكة العصبونية.....	59
6-3-1-4	مشكلة التدريب الزائد Over-fitting وكيفية حلها.....	67
7-3-1-4	بعض التطبيقات الطبية للشبكات العصبونية.....	69
2-4	طرق تقييم دقة تصنيف أنظمة التشخيص الطبي.....	69
3-4	بيئة عمل الماتلاب MATLAB الخاص بالشبكات العصبونية.....	74
4-4	تحويل فورييه (FT) Fourier Transformer.....	74
5-4	دراسة علاقة الترابط الخطي بين متحولين عشوائيين Linear Correlation.....	75
	الفصل الخامس: التجارب العملية.....	79
1-5	مقدمة.....	80
2-5	الحصول على عينات التدريب من جهاز PFT وتقسيم بيانات الدخل.....	81
3-5	تحليل العينات والمعالجة الأولية.....	86
1-3-5	تشخيص العينات حسب رأي الطبيب الخبير.....	86

89.....	2-3-5 تشخيص العينات حسب برنامج التشخيص في جهاز PFT
92.....	4-5 تحديد نوع الشبكة العصبونية وبنيتها وتحضير البيانات اللازمة لتدريبها
94.....	5-5 خطة العمل المتبعة لتحصيل النتائج
101.....	1-5-5 التجربة الأولى: تدريب الشبكة على المجموعة الأولى
106.....	2-5-5 التجربة الثانية: تدريب الشبكة على المجموعة الثانية
110.....	3-5-5 التجربة الثالثة: تدريب الشبكة على المجموعة الثالثة
118.....	4-5-5 التجربة الرابعة: تقييم دقة تصنيف برنامج جهاز وظائف الرئة
119.....	6-5 تقييم دقة تصنيف تجارب الشبكة العصبونية
120.....	1-6-5 تقييم نتائج الشبكة MLP على عينات الفحص للمجموعة الأولى
121.....	2-6-5 تقييم نتائج الشبكة MLP على عينات الفحص للمجموعة الثانية
123.....	3-6-5 تقييم نتائج الشبكة MLP على عينات الفحص للمجموعة الثالثة
124.....	7-5 مثال تدريبي لأفضل النتائج للشبكات العصبونية
127.....	8-5 تقنية التوقف المبكر للتدريب Early Stopping Technique
130.....	الفصل السادس: تحليل ومناقشة النتائج
131.....	1-6 تصميم الشبكة العصبونية MLP وتحديد معاملاتها المثلى
131.....	1-1-6 نوع الشبكة العصبونية المصممة
131.....	2-1-6 أسلوب تسوية بيانات الدخل
132.....	3-1-6 نوع توابع التفعيل
132.....	4-1-6 عدد الطبقات المخفية وعدد العصبونات فيها
133.....	5-1-6 نوع خوارزمية التدريب
134.....	6-1-6 تغيير الأوزان والانزياحات الابتدائية
134.....	7-1-6 استخدام تقنية التوقف المبكر خلال عملية التدريب Early Stopping

135.....	2-6 نتائج الشبكة العصبونية المصممة على المجموعات الثلاث
136.....	3-6 نتائج الشبكة العصبونية على المجموعة الأولى باستخدام منحني ROC
138.....	4-6 نتائج الشبكة العصبونية على المجموعة الثانية باستخدام منحني ROC
139.....	5-6 نتائج الشبكة العصبونية على المجموعة الثالثة باستخدام منحني ROC
141.....	6-6 نتائج الخوارزمية LM على المجموعات الثلاث باستخدام منحني ROC
143.....	7-6 مقارنة نتائج أداء تصنيف الشبكة العصبونية المصممة باستخدام خوارزمية LM
144.....	8-6 مناقشة نتائج هذه الدراسة مع الدراسات المرجعية السابقة
147.....	الفصل السابع: الاستنتاجات والآفاق المستقبلية
148.....	1-7 ملخص العمل في البحث والأهداف المحققة
151.....	2-7 الصعوبات التي واجهناها خلال هذه الدراسة
152.....	3-7 نصائح وآفاق مستقبلية للبحث
154.....	المراجع
157.....	الملحقات
158.....	الملحق الأول: برنامج التدريب للشبكات العصبونية في بيئة الماتلاب
162.....	الملحق الثاني: نتائج بعض الحالات التدريبية لمجموعات البيانات المختلفة
167.....	الملحق الثالث: نتائج تقييم أداء الشبكة العصبونية على مجموعات بيانات الدخل الثلاث
173.....	الملحق الرابع: الأجزاء الرئيسة في جهاز PFT والمخطط الصندوقي لعمل الجهاز
184.....	الملحق الخامس: جدول الخوارزميات المستخدمة واختصاراتها في بيئة العمل الماتلاب

فهرس الأشكال

رقم الصفحة	الشكل
23	(1-2) عملية الدمج بين أنواع الشبكات العصبونية [3]
32	(1-3) تشريح الجهاز التنفسي مع مقطع لحويصل رئوي [26]
34	(2-3) النظام المتكامل لتبادل الغازات في جسم الإنسان [7]
36	(3-3) نموذج لعنفة القياس المستخدمة [7]
36	(4-3) مخطط الحجم والسعات في جهاز اختبار وظائف الرئة [6]
42	(5-3) الاستراتيجية المتبعة في تشخيص أمراض الجهاز التنفسي [8]
46	(6-3) منحنى الحجم-الزمن لحالة طبيعية في اختبار السعة الحيوية القسرية FVC
46	(7-3) منحنى التدفق - حجم لحالة طبيعية في اختبار السعة الحيوية القسرية
47	(8-3) أمثلة عن بعض الحالات المرضية وفق مخطط (تدفق-حجم) [6]
47	(9-3) أمثلة عن بعض الحالات المرضية وفق مخطط (حجم-زمن) [6]
54	(1-4) أسلوب عمل خوارزمية الانتشار الخلفي للخطأ في الشبكة المتعددة الطبقات [10]
60	(2-4) النموذج الرياضي للعصبون يوضح المكونات الأساسية [9]
63	(3-4) طبقات الشبكة العصبونية نوع مستقبلات متعددة الطبقات MLP [10]
72	(4-4) منحنى ROC مع أسلوب حساب المساحة المحصورة تحت المنحنى [14]
81	(1-5) نموذج مبدئي لبناء الشبكة العصبونية المطلوبة يعرض الطبقات الأساسية فيها والروابط
85	(2-5) توزع عينات مجموعة التدريب الأولى والثالثة والثانية مع المجموعة الرابعة
86	(a3-5) مخطط الميول العام لقياسات FVC وفق الأصناف الأربعة حسب تشخيص الطبيب
87	(b3-5) مخطط الميول العام لقياسات FEV1 وفق الأصناف الأربعة حسب تشخيص الطبيب
87	(c3-5) مخطط الميول العام لقياسات FEV1% وفق الأصناف الأربعة حسب تشخيص الطبيب
88	(d3-5) مخطط الميول العام لقياسات FEF وفق الأصناف الأربعة حسب تشخيص الطبيب
89	(a4-5) مخطط الميول العام لقياسات FVC وفق الأصناف الأربعة حسب تشخيص البرنامج
90	(b4-5) مخطط الميول العام لقياسات FEV1 وفق الأصناف الأربعة حسب تشخيص البرنامج
90	(c4-5) مخطط الميول العام لقياسات FEV1% وفق الأصناف الأربعة حسب تشخيص البرنامج
91	(d4-5) مخطط الميول العام لقياسات FEF وفق الأصناف الأربعة حسب تشخيص البرنامج
92	(5-5) أنواع الشبكات العصبونية واختبار الشبكة المناسبة
94	(6-5) مخطط صندوقي لخطوات التنفيذ العملي في بيئة عمل الماتلاب
100	(7-5) مخطط صندوقي يوضح مراحل التجارب العملية على مجموعات بيانات الدخل الثلاث

فهرس الأشكال والجداول

112	(8-5) مخطط الميول العام لمطال تحويل فورييه لمخطط التنفس تدفق-حجم حسب الطبيب
113	(9-5) مخطط الميول العام لمطال تحويل فورييه لمخطط التنفس حجم-زمن حسب الطبيب
119	(10-5) تقييم نظام تصنيف برنامج التشخيص الآلي لجهاز وظائف الرئة
121	(11-5) نتائج أداء تصنيف الشبكة العصبونية بالخوارزميات الأربعة على مجموعة البيانات الأولى
122	(12-5) نتائج أداء تصنيف الشبكة العصبونية بالخوارزميات الأربعة على مجموعة البيانات الثانية
124	(13-5) نتائج أداء تصنيف الشبكة العصبونية بالخوارزميات الأربعة على مجموعة البيانات الثالثة
125, 126	(14-5) أحد أفضل النتائج التي حصلنا عليها أثناء التدريب بإعدادات الجدول (5-7)
128	(15-5) مزايا تقنية التوقف المبكر عند التدريب للحفاظ على قدرة الشبكة على التعميم
137	(1-6) منحنيات الـ ROC لخوارزميات التدريب الأربعة من أجل مجموعة العينات الأولى
138	(2-6) منحنيات الـ ROC لخوارزميات التدريب الأربعة من أجل مجموعة العينات الثانية
140	(3-6) منحنيات الـ ROC لخوارزميات التدريب الأربعة من أجل مجموعة العينات الثالثة
141	(4-6) منحنيات الـ ROC للخوارزمية LM على مجموعات البيانات الثلاث
143	(5-6) مقارنة أداء تصنيف الشبكة العصبونية باستخدام الخوارزمية LM على المجموعة الأولى

فهرس الجداول

رقم الصفحة	الجدول
23	(1-2) نتائج تصنيف الشبكتين العصبونيتين المستخدمتين في [3]
24	(2-2) نتائج تصنيف أسلوب SVM المستخدمة في [23]
25	(3-2) نتائج تصنيف نوعي الشبكات العصبونية المستخدم في [4]
26	(4-2) معايير الأداء في التشخيص السريري الأولي دون استخدام جهاز PFT في [5]
26,27,28	(5-2) ملخص الدراسات المرجعية السابقة
41	(1-3) بعض أمراض الرئة وعلاقتها بقياسات جهاز PFT [6]
45	(2-3) قيم القياسات الناتجة عن اختبار السعة الحيوية للرئة FVC
57,58	(1-4) بعض أشهر الخوارزميات المستخدمة في تدريب الشبكات MLP [11]
61,62	(2-4) أنواع توابع التفعيل التي يمكن أن تستخدم في عصبونات الشبكة [11]
74	(3-4) تقييم جودة نظام التشخيص حسب المساحة المحصورة تحت منحنى ROC [14]
82	(1-5) القياسات الأساسية المستخدمة في تشخيص أمراض الرئة مقسمة إلى أربعة مجموعات
101	(a2-5) نتائج التجربة الأولى تسوية [-1,1] مع توابع قطعية وطبقتين مخفيتين

فهرس الأشكال والجداول

102	(b2-5) نتائج التجربة الأولى تسوية [0,1] مع توابع لوغاريتمية وطبقتين مخفيتين
103	(c2-5) نتائج التجربة الأولى تسوية [-1,1] مع توابع قطعية وطبقة مخفية وحيدة
104	(d2-5) نتائج التجربة الأولى تسوية [0,1] مع توابع لوغاريتمية وطبقة مخفية وحيدة
106	(a3-5) نتائج التجربة الثانية تسوية [-1,1] مع توابع قطعية وطبقتين مخفيتين
107	(b3-5) نتائج التجربة الثانية تسوية [0,1] مع توابع لوغاريتمية وطبقتين مخفيتين
108	(c3-5) نتائج التجربة الثانية تسوية [-1,1] مع توابع قطعية وطبقة مخفية وحيدة
109	(d3-5) نتائج التجربة الثانية تسوية [0,1] مع توابع لوغاريتمية وطبقة مخفية وحيدة
111	(4-5) خطوات حساب مطال تحويل فورييه على عينة مخطط التدفق مع الحجم
114	(a5-5) نتائج التجربة الثالثة تسوية [-1,1] مع توابع قطعية وطبقتين مخفيتين
115	(b5-5) نتائج التجربة الثالثة تسوية [0,1] مع توابع لوغاريتمية وطبقتين مخفيتين
116	(c5-5) نتائج التجربة الثالثة تسوية [-1,1] مع توابع قطعية وطبقة مخفية وحيدة
117	(d5-5) نتائج التجربة الثالثة تسوية [0,1] مع توابع لوغاريتمية وطبقة مخفية وحيدة
120	(6-5) إعدادات الشبكة العصبونية المصممة حسب الخوارزميات الأربعة في المجموعة الأولى
122	(7-5) إعدادات الشبكة العصبونية المصممة حسب الخوارزميات الأربعة في المجموعة الثانية
123	(8-5) إعدادات الشبكة العصبونية المصممة حسب الخوارزميات الأربعة في المجموعة الثالثة
125	(9-5) إعدادات الشبكة العصبونية في المثال التدريبي
127	(10-5) إعدادات الشبكة العصبونية توضح تقنية التوقف المبكر
136	(1-6) مقارنة نتائج تصنيف نماذج الشبكات العصبونية المختلفة مع برنامج جهاز PFT
144	(2-6) ملخص النتائج المستحصلة من هذه الدراسة

مصطلحات البحث

المصطلح	المعنى العلمي للمصطلح
ANN	شبكة عصبونية اصطناعية Artificial Neural Network
FVC	السعة الحيوية القسرية Forced Vital Capacity
FEV1	حجم هواء الزفير القسري عند الثانية الأولى من الزفير
FEV1%	النسبة المئوية لحاصل القسمة FEV1/FVC
MLP	مستقبلات متعددة الطبقات Multi-Layer Perceptron
LM	خوارزمية التدريب من النوع Levenberg Marquardt
PFT	جهاز اختبار وظائف الرئة Pulmonary Function Test
ERS	الجمعية الأوروبية للأمراض التنفسي European Respiratory Society
ATS	الجمعية الأمريكية لأمراض الصدر American Thoracic Society
MATLAB	بيئة محاكاة ونمذجة للمسائل الحسابية واختبار الشبكة العصبونية
COSMED	الشركة المصنعة لجهاز اختبار وظائف الرئة
RBF	شبكة عصبونية ذات توابع قاعدة شعاعية Radial Basis Functions
SOM	شبكة عصبونية ذاتية التنظيم Self-Organizing Map
LVQ	شبكة عصبونية تكميم شعاع التعلم Learning Vector Quantization
FFT	تحويل فورييه السريع Fast Fourier Transformer
DFT	تحويل فورييه المتقطع Discrete Fourier Transformer
PNN	شبكة عصبونية احتمالية Probabilistic Neural Network
SVM	أسلوب تصنيف من النوع Support Vector Machine
FEF	تدفق الزفير القسري Forced Expiratory Flow
PCA	تحليل المكونات الرئيسية Principal Component Analysis
Elman	شبكة عصبونية ذات تغذية خلفية جزئية
BP	خوارزمية الانتشار الخلفي Back-propagation
BR	خوارزمية التدريب من النوع Bayesian Regularization

Resilient Back-propagation خوارزمية التدريب من النوع	RB
Scaled Conjugate Gradient Back-propagation خوارزمية التدريب من النوع	SCG
Receiver Operating Characteristics منحني مميزات التشغيل	ROC
Total Lung Capacity سعة كامل الرئة	TLC
Vital Capacity السعة الحيوية	VC
Inspiration Capacity سعة الشهيق	IC
Residual Volume الحجم المتبقي	RV
Functional Residual Capacity السعة المتبقية الوظيفية	FRC
Inspiratory Residual Volume حجم الشهيق المتبقي	IRV
Tidal Volume الحجم المُدي	V _T
Expiratory Residual Volume حجم الزفير المتبقي	ERV
Chorionic Obstructive Pulmonary Diseases ذات الرئة المزمن	COPD
Pulmonary Vascular Disease مرض بالأوعية الرئوية	PVD
Diffusion Capacity سعة الانتشار (اختبار)	DL _{CO}
Peak Expiratory Flow تدفق الزفير الأعظمي	PEF
Low Level Normal السوية الدنيا الطبيعية	LLN
قيم متنبأ بها اعتماداً على دراسات إحصائية	%Pred.
Feed Forward Network شبكة عصبونية بتغذية أمامية	FFN
Feed-Back Network شبكة عصبونية بتغذية خلفية	FBN
General Regression Neural Network شبكة عصبونية بانكفاء عام	GRNN
Mean Square Error متوسط مربع الخطأ	MSE
Sum Square Error مجموعة مربع الخطأ	SSE
Early Stopping تقنية التوقف المبكر	ES
Gradient Descent with Momentum Back-propagation خوارزمية التدريب من النوع	GDM
Polak-Ribiere Conjugate Gradient Back-propagation خوارزمية التدريب من النوع	CGP

One Step Secant Back-propagation خوارزمية التدريب من النوع	OSS
Fletcher-Powell Conjugate Gradient Back-propagation خوارزمية التدريب من النوع	CGF
Powell-Beale Conjugate Gradient Back-propagation خوارزمية التدريب من النوع	CGB
Gradient Descent with Adaptive Learning Rule خوارزمية التدريب من النوع	GDA
Gradient Descent Back-propagation خوارزمية التدريب من النوع	GD
Learning Rate معدل التعلم	LR
Negative Predictive Value قيمة التنبؤ السلبية	NPV
Positive Predictive Value قيمة التنبؤ الإيجابية	PPV
Area Under Curve ROC مساحة السطح المحصور تحت منحنى	AUC
Mean Expiratory Flow متوسط تدفق الزفير عند 75% من زمن الزفير	MEF75%
Mean Expiratory Flow متوسط تدفق الزفير عند 50% من زمن الزفير	MEF50%
Mean Expiratory Flow متوسط تدفق الزفير عند 25% من زمن الزفير	MEF25%
مجموعة بيانات الدخل الأولى (201 عينة ذات 23 قياس)	23p201
مجموعة بيانات الدخل الثانية (380 عينة ذات 13 قياس)	13p380
مجموعة بيانات الدخل الأولى (201 عينة ذات 25 قياس)	25p201

الفصل الأول

مقدمة الدراسة

1-1 مقدمة عامة

يعد مجال هذا البحث من المجالات المهمة في مجال استخدام تقنيات الذكاء الصناعي في تطبيقات الهندسة الطبية، حيث أنه يتم توظيف قدرات الشبكات العصبونية الصناعية على التعلم واكتساب الخبرة خلال التدريب لأهداف طبية متقدمة. تكمن أهمية هذا البحث في إبراز الدور الكبير الذي يمكن أن تلعبه تقنيات الذكاء الصناعي في جميع المجالات الطبية التي يمكن أن تساعد الطاقم الطبي وخاصة الأطباء في تسهيل التواصل بين الإنسان والآلة والتشخيص المبكر للأمراض الذي بدوره يساعد في سهولة العلاج علاوة على مراقبة سير الخطة العلاجية من خلال التغذية الخلفية الراجعة.

2-1 المشكلة المدروسة:

تعتبر عملية التشخيص الآلي لأمراض الجهاز التنفسي اعتماداً على القياسات الفيزيولوجية لجهاز التنفس عند المريض من المهام المعقدة بالنسبة لأي نظام تشخيص آلي بسبب عدم قدرته على الإلمام بكافة المتغيرات المتعلقة بالمرض المراد كشفه والتعرف عليه. كما أن الوقت المستغرق من قبل الأطباء أو الطاقم الطبي لكشف المرض يمكن أن يؤخر فرص علاج المرض بالسرعة الكافية.

في بحثنا هذا، درسنا إمكانية تصميم شبكة عصبونية لمعالجة نتائج الفحص التي تم الحصول عليها من اختبارات جهاز وظائف الرئة التنفسية التي هي مجموعة قياسات محددة لحالة جهاز التنفس السريرية عند المريض بحيث يتمكن هذا البرنامج من تصنيف حالة المريض بين عدة حالات مرضية بناءً على قدرة التعلم التي اكتسبها البرنامج خلال عملية التدريب المدروسة والمنقاة من حالات مدروسة مسبقاً وإحصائيات واقعية.

3-1 الفائدة من البحث

تكمن الفائدة من هذا البحث بأنه يدرس القدرة على تصميم برامج تستخدم الشبكات العصبونية ليصار إلى إضافتها إلى جهاز وظائف الرئة التنفسية وذلك من أجل استخدام هذه البرامج في مجال التشخيص الآلي لهذا الجهاز مما يساعد على زيادة الدقة في كشف أمراض التنفس عند الإنسان.

1-4 فكرة البحث

تعتمد فكرة البحث على الاستفادة من كمية البيانات الكبيرة والمتنوعة التي نحصل عليها من جهاز وظائف الرئة Pulmonary Function Test PFT أثناء انجاز اختبار الفحص على المريض للتأكد من حسن أداء الوظيفة التنفسية وفق معايير الفحص العالمية التي تتص عليها جمعية الأمراض التنفسية الأوروبية (European Respiratory Society (ERS وجمعية الأمراض الصدرية الأمريكية (ATS) American Thoracic Society. يمكن للعدد الكبير من البيانات الناتجة عن الجهاز أن تستهلك وقت وجهد الطبيب في الحسابات والتشخيص وخاصة في حالة قلة الخبرة والسرعة للأطباء الذين يجدون صعوبة وحيرة في حالات معقدة ومتقاربة مما يجعل اتخاذ قرار التشخيص أمر غير سهل.

يهتم هذا البحث بدراسة إمكانية استخدام الشبكات العصبونية لمعالجة كمية البيانات الكبيرة التي نحصل عليها من خرج جهاز فحص الرئة عند الإنسان.

بكلام آخر، تعتمد فكرة البحث على حقيقة أن المسائل في الأنظمة الخطية تسلك دائماً سلوكاً خطياً أي يتناسب فيها تغير الدخل مع تغير الخرج وفق معادلات يمكن حلها بالطرق الرياضية التفاضلية أو الجبرية، أما بالنسبة للأنظمة غير الخطية التي فيها تكون تغيرات الدخل مع الخرج غير متناسبة فإننا نحاول إيجاد العلاقة الناعمة لسلوك هذه الأنظمة، وفي حال كان النظام معقداً ولدينا كمية كبيرة من البيانات (دخل-خرج) للمسألة - كما هو الحال في هذا البحث - فإننا نلجأ إلى استخدام تقنيات أخرى مثل الشبكات العصبونية الصناعية والتي تعرف بالصندوق الأسود Black Box التي تحاكي في بنائها طريقة التفكير والتحليل لدى الإنسان. لهذه الشبكات العديد من الأنواع والأساليب لإكتساب المعرفة أو التعلم ونذكر منها على سبيل المثال عناصر الإدراك متعددة الطبقات (Multi-Layer Perceptron (MLP التي غالباً ما تستخدم في الأنظمة غير الخطية وفي تطبيقات التصنيف والفرز وفي الغالب تتكون من طبقة دخل (عدد عصبونات الدخل تتعلق بالقياسات) وطبقة خرج (عدد عصبونات الخرج تتعلق بنتائج خرج الشبكة) وطبقة مخفية يمكن أن تكون طبقة واحدة أو أكثر حسب مدى تعقيد المسألة (عصبونات

مخفية تتعلق بفضاء العينة للتائج المتوقعة) وتتصل هذه العصبونات مع بعضها بروابط تحكمها أوزان يتم تحديدها بعد انتهاء عملية التعلم والتدريب.

1- 5 أهداف البحث

الهدف الرئيسي لهذا البحث العلمي هو إيجاد نظام تشخيص آلي قادر على تصنيف عينات الفحص المأخوذة من جهاز وظائف الرئة إلى حالات سليمة وحالات مرضية وذلك باستخدام الشبكات العصبونية الصناعية، بالإضافة إلى إمكانية تصنيف الحالات المرضية إلى زمرة أمراض أكثر تحديداً مما يساعد ويحسن من مهمة الطبيب في الوصول إلى التشخيص الصحيح. يحتاج هذا الهدف تحقيق عدد من الأهداف الإضافية و هي:

- 1- الدراسة المرجعية لأهم الأبحاث التي تناولت موضوع تصنيف أمراض اختبارات وظائف الرئة باستخدام الشبكات العصبونية الصناعية كما سوف يرد ذكره في الفصل الثاني.
- 2- دراسة العلاقات والروابط بين أمراض الجهاز التنفسي واختبار وظائف الرئة الذي يعتمد عليه الطبيب في التشخيص هذا النوع من الأمراض ودور الجهاز المهم في زيادة كفاءة الكشف لهذا النوع من الأمراض مقارنة مع أساليب التشخيص السريرية التقليدية. بالإضافة إلى دراسة ارتباط كل قياس من قياسات اختبار وظائف الرئة مع أصناف الأمراض الرئيسية والتعرف على استراتيجيات الأطباء في التشخيص ضمن هذا المجال, كما سيتم شرحه في الفصل الثالث.
- 3- دراسة تقنيات الذكاء الصناعي (الشبكات العصبونية الصناعية ANNs) والأنظمة الخبيرة المستخدمة في هذا المجال من حيث البنية وتجهيز البيانات وأنواعها ومدخلاتها والخوارزميات الذكية المستخدمة فيها، وتركيز البحث على الأنواع التي تتخصص في تصنيف البيانات والتي من أهمها: الشبكات العصبونية متعددة الطبقات (Multi-Layer Perceptron (MLP والشبكات العصبونية ذات توابع القاعدة الشعاعية (Radial Basis Function (RBF والشبكات العصبونية ذاتية التعلم والتنظيم (Self-Organized Map (SOM وشبكات تكميم شعاع التعلم (Learning Vector Quantization (LVQ). وقد تم التركيز على الشبكات نوع MLP بسبب الحصول على نتائج مرضية من حيث دقة التصنيف، و دراسة بنى هذه الشبكة من حيث عدد الطبقات

والعصبونات المكونة منها بالإضافة لطرق المعالجة الأولية والخوارزميات المتعددة المستخدمة لتعليمها، حيث نجد في الفصل الرابع شرح مفصل عن هذه النقاط.

4- دراسة إمكانية تصميم نموذج لتصنيف العينات المستحصلة قادر على تحقيق نتائج موثوقة طبياً من حيث دقة التصنيف في الحالات السليمة المرضية بنسب خطأ مقبول. وقد تم دراسة البيانات الأولية وانتقاء نمط المعالجة الأولية اللازم حيث يتوافق مع الشبكة العصبونية واستخدام خوارزميات تدريب عديدة ومتنوعة تعتمد على تقنيات التوقف الآلي الذي يحمي الشبكة العصبونية من المبالغة في عملية التعلم (الحفظ كذاكرة تخزين) بل يزيد من دقة التصنيف. يحتوي الفصل الخامس التجارب التي تم إجراؤها ومراحل العمل لتحقيق هذا الهدف وتمت مناقشتها في الفصل السادس.

5- دراسة نمط التصنيف التقليدي المتبع في أجهزة وظائف الرئة (مقياس التنفس Spirometer) وتقييم نتائج تصنيفه المطبقة على الجهاز للتحقق من وثوقية التصنيف والتأكد من صلاحيته لتطبيقات التشخيص الطبي كما هو موضح في الفصل الخامس، ثم إجراء المقارنة بين نتائج التصنيف التقليدي ونتائج الشبكات العصبونية.

6- دراسة إمكانية إضافة قياسات تشخيصية جديدة تعتمد على حساب مطال تحويل فورييه Fourier Transformer (FT) لاستخراج بعض المميزات من مخطط (التدفق-الحجم) ومخطط (الحجم-الزمن) بحيث يمكن أن تضاف بشكل ناهج ومفيد إلى مدخلات الشبكات العصبونية وتكون ذات أهمية في رفع دقة التصنيف وتحسين النتائج (الفصل الخامس).

7- مقارنة النتائج المستحصلة من الشبكة العصبونية المصممة مع مثيلاتها التي تم نشرها في الأوراق كما ورد في الفصل الخامس.

1- 6 خطة البحث في الفصول اللاحقة

عملنا على تنظيم الدراسة في الفصول اللاحقة كالتالي:

الفصل الأول: هو الفصل الحالي الذي تم فيه عرض المشكلة المدروسة وأهداف البحث والفائدة منه والخطوات والأهداف التي سندرسها في هذا البحث العلمي.

الفصل الثاني: عرضنا الدراسات المرجعية الحديثة لأبحاث سابقة تم انجازها مسبقاً متعلقة بالبحث المطروح وتم إجراء مقارنة مفصلة لعدد من الدراسات الحديثة من حيث القياسات المستخدمة في كل دراسة وبنى الشبكات العصبونية وأساليب الذكاء الصناعي والمعالجة الأولية للبيانات بالإضافة لعدد العينات والنتائج النهائية للدراسات.

الفصل الثالث: تحدثنا عن تشريح وفيزيولوجيا الجهاز التنفسي بشكل سريع وشرحنا بشكل أكثر تفصيلاً جهاز وظائف الرئة المستخدمة بشكل أساسي في إختبارات وظائف الرئة ودورها في تقييم وظيفة الجهاز التنفسي. كما وتعرفنا على أمراض الجهاز التنفسي التي يتم كشفها باستخدام هذا النوع من الأجهزة والقياسات التي يقيسها الجهاز وعلاقتها الوثيقة بالحالات السليمة والمرضية الرئيسية حسب المعايير العالمية لتشخيص هذه الأمراض ETS و ERS. بالإضافة لعرض تفاصيل الإجراءات المستخدمة بشكل عملي من قبل الطبيب الخبير لتصنيف الحالة المدروسة من قراءة تقرير اختبار وظائف الرئة للمريض.

الفصل الرابع: شمل هذا الفصل عرض لأساليب التشخيص المحوسب والتي تشمل طريقة الشبكات العصبونية الصناعية المستخدمة في الدراسة، وشرح تفصيلي لطريقة الشبكات العصبونية متعددة الطبقات MLPNNs من حيث الخوارزميات المستخدمة وطرق المعالجة الأولية والمساوئ والمحسن. يشرح هذا الفصل أيضاً أساليب تقييم دقة التصنيف لأنظمة التشخيص الطبي ومجالات صلاحيتها.

الفصل الخامس: تضمن هذا الفصل الجانب العملي للدراسة والأساليب المستخدمة للوصول إلى النتائج النهائية من حيث تحصيل بيانات الدخل اللازمة للشبكة العصبونية وتقسيمها وتحليلها والمعالجة الأولية. شمل هذا الفصل أيضاً المراحل الأساسية للتجارب التي تم إجراؤها على مجموعات بيانات الدخل وطريقة تقييم نظام التشخيص التقليدي لجهاز وظائف الرئة المعتمد على معايير تشخيص أمراض الجهاز التنفسي العالمية. في هذا الفصل تم عرض فكرة إضافة قياسين جديدين من مخططي التدفق-الحجم والحجم-الزمن بإجراء تحويل فوربييه على كل منهما وحساب الطاقة الطيفية بحيث تفيد في زيادة وثوقية نتائج التصنيف.

الفصل السادس: تم مناقشة النتائج التي تم تحصيلها في مراحل الدراسة العملية المذكورة في الفصل الخامس وتعليل أسباب نجاحها أو عدم وصولها للمطلوب، بالإضافة لمقارنة النتائج مع الدراسات السابقة.

الفصل السابع: احتوى هذا الفصل على ملخص لكامل الدراسة وتقييم كامل للنتائج وتحديد الآفاق المستقبلية.

الخلاصة:

عرضنا في هذا الفصل المشكلة المطروحة للدراسة والأهداف الرئيسة التي تتلخص في رفع أداء التشخيص الآلي لجهاز وظائف الرئة PFT باستخدام أساليب وطرق الذكاء الصناعي والفوائد التي يمكن أن نجنيها من تحقيقها. كما وتحدثنا باختصار عن الفكرة الأساسية لتنفيذ هذا البحث وخطوات التنفيذ العملية للوصول إلى الهدف المطلوب. سنتطرق في الفصل القادم إلى مناقشة عدد من الأبحاث السابقة المشابهة لبحثنا لتبيان أوجه التشابه والاختلاف مع استعراض لأهم النتائج المستحصلة في هذه الأبحاث ليصار إلى مقارنتها مع تلك التي تم تحصيلها في بحثنا (الفصل الخامس والسادس).

الفصل الثاني

الدراسات المرجعية

2- 1 الدراسات المرجعية السابقة لأعمال مماثلة لمجال البحث المقترح

قام الباحث K. Waghmare وزملاؤه في عام 2012 باستخدام عدة أنواع من الشبكات العصبونية مثل العصبونات المتعددة الطبقات Multilayer Perceptron (MLPNN) وشبكات ذات تابع أساس شعاعي Radial Basis Function (RBF) مع 150 عينة تدريب تم أخذها من جهاز قياس تنفس معياري تتضمن قياسات مثل FEV1 و SVC بالإضافة لعمر وجنس وسلالة المريض مع استخدام أساليب التعليم الذاتي للشبكات نوع Self-Organized Map (SOM) حيث تم تصنيف العينات لثلاثة أصناف هي سليمة Normal وسادة Obstructive وقاصرة Restrictive بشكل ناجح [15].

قام الباحث P. Junwale وزملاؤه في عام 2012 بالاعتماد على تقنية Data Mining بدراسة القياسات الأساسية في تشخيص أمراض الجهاز التنفسي المأخوذة من اختبار وظائف الرئة مثل FEV1 و FEV1/FVC وغيرها من القياسات لاستنتاج قيم جديدة للتفريق بين أصناف أمراض الرئة الرئيسية مثل صنف الأمراض السادة Obstructive والقاصرة Restrictive والمختلطة Mixed وتمكنوا من الحصول على نتائج مشجعة تمكنوا من تحسينها بمساعدة تقنية معروفة باسم ANOVA [16].

قام الباحث Orhan Er وزملاؤه في عام 2010 باستخدام عدة أنواع من الشبكات العصبونية منها عصبونات متعددة الطبقات Multilayer Perceptron (MLPNN) وشبكات احتمالية Probabilistic (PNN) وشبكات تكميم شعاع التعلم Learning Vector Quantization (LVQ) وشبكات ذات تابع أساس شعاعي Radial Basis Function (RBF) لتدريب 357 عينة ذات 38 مركبة تضمنت قياسات مثل حرارة جسم الانسان وفحوصات مخبرية للدم وغيرها وذلك لتصنيف أمراض الرئة لستة أصناف 5 مرضية هي مرض السل Tuberculosis ومرض انسداد الرئة المزمن COPD والالتهاب الرئوي Pneumonia والربو Asthma وسرطان الرئة Lung Cancer وصنف سليم وحصلوا على دقة تصنيف تصل لـ 90% [18].

قام الباحث A. Kavitha في عام 2010 مع زملاؤه باستخدام تحليل Support Vector Regression والشبكات العصبونية ذات تابع الأساس الشعاعي RBF للتنبؤ بأهم قياس مستخدم في تشخيص أمراض الرئة FEV1 حيث اعتمدت الدراسة على 175 عينة مأخوذة من جهاز وظائف رئة معياري تحتوي


قياسات التشخيص الأساسية FVC و FEF بهدف التفريق بين الحالات المرضية والسليمة بشكل جيد حتى في حالات نقص المعلومات المدخلة. حيث كانت دقة التنبؤ عالية (قيمة) من أجل الحالات الطبيعية أكثر من الحالات المرضية وتوصلوا لنتيجة مفادها أن قياس FEV1 من أهم القياسات المستخدمة في تحليل قياسات الوظيفة التنفسية، لذلك كانت الطريقة المطروحة مساعدة في تشخيص الحالات المرضية الرئوية حتى في حالة البيانات غير المكتملة عند أخذ العينات [17].

في عام 2009 قام الباحث S. Jafari وزملاؤه باستخدام الشبكات العصبونية متعددة الطبقات MLPNN مع خوارزمية Levenberg Marquardt (LM) لتصنيف 205 عينة تحتوي قياسات أساسية تصل لـ 9 قياسات مثل FVC و FEV1 و FEV1% بالإضافة للقيم المتتبا بها المستنتجة من وزن وطول وعمر المريض إلى أربعة أصناف: حالة سليمة ومرض ساد Obstructive ومرض قصور Restrictive ومرض مختلط Mixed للحصول على دقة تصنيف جيد تصل لـ 97.6%. تم استخدام توابع قطعية Tan-sigmoid للعصبونات وتوابع تفعيل خطية للخروج مع تقنية التوقف المبكر للحفاظ على تعميم الشبكة، كما واستخدم طبقة مخفية وحيدة وطبقتين مع عدد عصبونات مخفية متنوع [19].

قام الباحث A. Kavitha في عام 2009 وزملاؤه باستخدام الشبكات العصبونية متعددة الطبقات MLPNN مع طريقة تحليل المكونات الرئيسية Principal Component Analysis (PCA) لتحليل الترابط الداخلي لمجموعة بيانات عينات الدخل التي بلغ عددها 175 عينة من أجل التنبؤ بقيمة FEV1 ذات الأهمية البالغة في تشخيص أمراض الجهاز التنفسي وقد تمكنوا من تمييز العينات ذات الحالات السليمة من الحالات المرضية بشكل ممتاز حتى في حالة المعلومات الناقصة. بالإضافة إلى أن تحليل قيم هذا القياس الهام إحصائياً باتباع طريقة PCA قادر على وصف سلوك الجهاز التنفسي وذلك يعود للترابط العالي للقياسات التنفسية المقاسة [20].

في عام 2008 قام الباحث M. Baemani وزملاؤه بدمج نوعين من الشبكات العصبونية هي عصبونات متعددة الطبقات MLPNN مع شبكات تكرارية (جزئياً) من نوع Elman كما هو موضح في الشكل (1-2)، حيث يقوم كل نوع بجزء من عملية التصنيف الكلية التي تم تطبيقها على 250 عينة بحيث يتم

تصنيفها إلى ثلاثة أصناف: في المرحلة الأولى تم التصنيف إلى حالة سليمة Normal أو حالة مرضية Abnormal, وفي المرحلة الثانية تم تصنيف الحالات المرضية إلى حالة علة سادة Obstructive أو علة Restrictive.



الشكل (1-2) الدمج في أنواع الشبكات العصبونية ينتج عنه دقة أكبر باستخدام شبكتين عصبونيتين والتي فيها تتجزأ الأولى جزء من التشخيص و تعطي النتائج كمدخل للطبقة اللاحقة, مأخوذ عن [3].

يلي ذلك مقارنة النتائج مع طريقة إحصائية لتمييز العينات هي Step Wise Discriminant, وقد توصلوا إلى أن الدمج بين الشبكات يساعد على الاستفادة من محاسن كل نوع وبالتالي زيادة دقة التصنيف الكلية (فيما لو تم استخدام نوع وحيد), كما أن دقة التصنيف للشبكات العصبونية المقترحة كانت ذات دقة أكبر من الطريقة الإحصائية. يوضح الجدول (1-2) نتائج التصنيف في كل شبكة وفق الدقة Accuracy والحساسية Sensitivity والنوعية Specificity [3].

الجدول (1-2) نتائج تصنيف الشبكتين العصبونيتين المستخدمتين في [3]

	Accuracy	Sensitivity	Specificity
Normal (ANN1)	92%	95%	92.5%
Obstructive (ANN2)	92.5%	90%	91.5%
Restrictive (ANN2)	92.5%	93%	91.5%

استخدم الباحث D. Sahin وزملاؤه في عام 2009 طريقة Support Vector Machines (SVM) وفق أسلوب ترميز مخارج تصحيح الخطأ ECOC التي تستخدم توابع أساس شعاعي RBF كتوابع نواة Kernel Function بهدف تشخيص عينات جهاز وظائف الرئة إلى 3 أنماط رئيسية سليمة وسادة وقصور من

أجل 455 عينة فحص تضمنت 3 قياسات أساسية في الاختبار هي FVC و FEV1 و FEV1% وقد حصلوا على نتائج التصنيف الموضحة في الجدول (2-2) [23].

الجدول (2-2) نتائج تصنيف طريقة SVM المستخدمة في [23]

Classification Accuracies	Values (%)
Specificity	97.97
Sensitivity (Restrictive)	94.44
Sensitivity (Obstructive)	94.29
Total classification accuracy	97.32

قام الباحث S. Manoharan في عام 2008 وزملاؤه بتنفيذ دراسة للكشف عن اعتلالات الجهاز التنفسي باستخدام شبكات عصبونية ذات تابع أساس شعاعي Radial Basis Function (RBF) بالتعليم الموجه، تعتبر شبكات RBF مفيدة في نمذجة البيانات غير الخطية ويمكن تدريبها في مرحلة واحدة عوضاً عن استخدام العملية التكرارية كما في عناصر الإدراك متعددة الطبقات و أيضاً يمكن أن تتعلم التطبيقات المعطاة بسرعة وقد أظهرت النتائج أن الأسلوب المقترح مفيد في تصنيف وظائف الرئة إلى حالات طبيعية Normal ومرضية (سادة Obstructive أو قصور Restrictive) وكانت دقة التصنيف 100%. وتم إجراء مقارنة هذه الأسلوب في التصنيف مع أسلوب الشبكات العصبونية متعددة الطبقات ذات الانتشار الخلفي Back Propagation Multi-Layer Perceptron (MLP) التي تعتمد مبدأ التغذية الخلفية التكرارية، وتم تدريب كلا الأسلوبين على تصنيف 100 عينة تدريب و تم اختبارها بـ 50 عينة فحص تضمنت القياسات التي يقدمها جهاز قياس التنفس الأساسية وهي FVC و FEV1 و FEV1% وكانت دقة التصنيف 96%. أظهرت النتائج أن الأسلوبين ناجحين في تصنيف بيانات الوظيفة الرئوية المستحصلة من جهاز مقياس التنفس Spirometer القياسي، وأن الشبكات ذات تابع الأساس الشعاعي RBF أكثر حساسية ودقة بالمقارنة مع شبكات الانتشار الخلفي. يبين الجدول (3-2) نتائج التصنيف بالتفصيل [4].

الجدول (2-3) نتائج تصنيف نوعي الشبكات العصبونية المستخدمة في [4]

Indices	MLP	RBF
Accuracy	96%	100%
Sensitivity (True Positive Rate)	100%	100%
Specificity	92.59%	100%
False Positive Rate (1-Specificity)	7.41%	0%
Positive Predictive Value	92%	100%
Negative Predictive Value	100%	100%

في عام 2007 استخدم الباحث M. Veezhinathan وزملاؤه الشبكات العصبونية ذات تابع أساس شعاعي RBF لكشف الحالات الغير طبيعية في مخططات التدفق-الحجم من أجل 100 عينة تتضمن قيم مقياس التنفس الأساسية بالإضافة لمخططات مشتقة تتضمن قيم الضغط والمقاومة مع الزمن، وقد تم التصنيف إلى حالتين سليمة ومرضية (سادة Obstructive) والنتائج المستحصلة كانت ذات دقة تصل إلى 90% وحساسية 92% ونوعية 88% [21].

استخدم الباحث S. Manoharan وزملاؤه عام 2008 شبكات عصبونية نوع RBF للتنبؤ بقيمة FEV1 بشكل دقيق مع عينات غير مكتملة، وقد استخدموا أسلوب k-means Clustering لتحديد المراكز الأفضل لتوابع القاعدة الخاصة بالعصبونات المخفية في الشبكة العصبونية، ثم حساب خطأ التنبؤ والقيم الاحصائية مثل الانحراف المعياري والمتوسط بالإضافة لدراسة ترابط هذه المعايير الاحصائية مع البيانات الأولية من أجل الحالات السليمة والسادة والقاصرة بشكل جيد. وقد أظهرت النتائج أن دقة التنبؤ بالحالات السادة أعلى منها في الحالات القاصرة، وأن هذه الطريقة تساعد بفعالية في تشخيص اعتلالات الجهاز التنفسي حتى في حالة وجود بيانات أولية غير كافية [22].

في عام 1998 نشر أطباء في جامعة الكويت للطب مقالة في المجلة العلمية Saudi Medicine حول القيمة التخمينية للتشخيص الأولي السريري لأمراض الجهاز التنفسي، فقاموا بإجراء دراسة احصائية عن مدى نجاح عمليات التشخيص من قبل أطباء أصحاب خبرة بعد الاستعانة بجهاز وظائف الرئة PFT وقد توصلوا لنتيجة مفادها أن تشخيص الطبيب للأمراض التنفسية يكون غير كافٍ بدون جهاز فحص وظيفة

الرئة، وأن استخدام مثل هذا الجهاز في التشخيص أضحى ضرورة للحصول على نتائج أكثر دقة في التشخيص الطبي من تلك التي يتم انجازها بدون جهاز وظائف الرئة. اعتمدت هذه الدراسة الاحصائية على تقييم التشخيص السريري الأولي الذي يقوم به الطبيب لعدة أصناف مرضية مثل الربو Asthma وذات الرئة المزمن COPD وتليف الرئة Fibrosis وحساب معايير أداء التصنيف كالدقة والحساسية والنوعية والقيمة التنبؤية الموجبة (في حالة التشخيص دون استخدام جهاز PFT حيث كانت معايير الأداء منخفضة وغير معتمدة طبياً) كما هو موضح في الجدول (2-4) [5].

الجدول (2-4) معايير الأداء لأسلوب التشخيص السريري الأولي دون استخدام جهاز PFT في [5]

التشخيص الأولي	الدقة (%)	الحساسية (%)	النوعية (%)	القيمة التنبؤية الموجبة (%)
الربو Asthma	70.8	51.0	82.8	64.1
ذات الرئة COPD	74.5	17.8	97.5	74.2
تليف Fibrosis	87.1	24.5	97.5	61.9

يوضح الجدول (2-5) ملخص جميع الدراسات السابقة التي جئنا على ذكرها في هذه الفقرة . يُقسم الجدول إلى عدد من الأعمدة حيث يبين العمود الأول رقم المرجع والثاني سنة النشر والثالث عنوان المقالة والرابع اسم الباحث الأول المشارك في الدراسة، بينما يُشير العمود الخامس إلى قياسات جهاز اختبار وظائف الرئة المستخدمة في البحث، ويدل العمود السادس على طريقة الذكاء الصناعي أو الشبكات العصبونية المستخدمة، في حين أن العمود السابع يعرض عدد العينات المستخدمة والعمود الثامن النتائج.

الجدول (2-5) ملخص الدراسات المرجعية السابقة

المرجع	السنة	العنوان	المؤلفون	عدد القياسات المستخدمة	منهجية الذكاء الصناعي	عينة	النتائج النهائية والمخرجات
[15]	2012 Jan	Spirometry Data Analysis and Classification Using Artificial Neural Networks: An Approach	K. Waghmare	FVC, FEV1, SVC, MVV Predicted Value (age, gender, race)	ANN SOM	150	3 classes: (Normal, Obstructive, Restrictive Well-classified and predicted spirometer parameter

[16]	2011	Statistical Data Mining Approach for Spirometric Data Classification: Review Paper.	P. Junwal e	FVC, FEV1, FEV1/FVC, PEF, FIT, FET	Statistical Data Mining with ANOVA technique	N.A	4 classes: Normal, Obstructive, Restrictive, Mixed.
[17]	2010 Mar	Prediction of Spirometric Forced Expiratory Volume (FEV1) Data Using Support Vector Regression	A. Kavitha	FEV1	SVM, support vector regression model employing polynomial kernel	175	3 classes: Normal, Obstructive, Restrictive Prediction of FEV1 value using SVM which is the most important value for diagnosis in case of incomplete dataset.
[19]	2010 April	Classification of Normal and Abnormal Respiration Patterns Using Flow Volume Curve and Neural Network	S. Jafari	10 inputs, FVC, FEV1, FEV1%, PEF, Predicted (age, height, gender, race)	ANN MLP LM	205	4 classes: Normal, Obstructive, Restrictive, Mixed. Accuracy= 97.56, Sensitivity=97.5, Specificity= 98.8.
[18]	2010	Chest diseases diagnosis using artificial neural networks	Orhan Er	Laboratory examination tests (blood, urea, ions, temperature,etc)	MLPNN, PNN, LVQ, GRNN, RBF	357	6 classes: Tuberculosis, COPD, Pneumonia, Asthma, Lung Cancer, Normal MLPNN:BPwM=90.76 MLPNN:LM=91.6 PNN=92.16 LVQ=88.52 GRNN=88.24 RBF=90.2
[23]	2009 Jan	Diagnosis of Airway Obstructive or Restrictive Spirometric Patterns by Multiclass Support Vector Machines	D. Sahin	FEV1, FVC, FEV1/FVC	SVMs, Multiclass, ECOC: Error Correcting Output Codes	455	3 classes: Normal, Obstructive, Restrictive Total classification accuracy of SVM is 97.32%

[20]	2009 Aug	Evaluation of Flow-Volume Spirometric Test Using Neural Network Based Prediction and Principal Component Analysis	A. Kavitha	18 Var: FVC, FEV1, PEF, FEF, Predicted(age, Height, Weight, gender)	MLP to predict FEV1 (PCA)	175	Prediction of FEV1 both in normal and abnormal with high accuracy
[22]	2008 May	Prediction of Forced Expiratory Volume in Pulmonary Function Test using Radial Basis Neural Networks and k-means Clustering	S. Manoharan	Spirio Data to predict FEV1 value	RBF, k-mean clustering algorithm to determine the optimal centers of the hidden layers of RBFs.	N.A	3 classes: Normal, Obstructive, Restrictive The network is capable of predicting FEV1 in both Normal & Abnormal; the prediction accuracy was more in obstructive compared to restrictive cases.
[3]	2008	Detection of Respiratory Abnormalities Using Artificial Neural Networks	M. Baemani	FVC, FEV1, VC, FEV1%, FEV1/VC, PEF	Combination of 2 types of: (MLP+ Elman)	250	3 classes: Normal, Obstructive, Restrictive Accuracy= 92;92.5%, Sensitivity= 95;93%, Specificity= 90;91.5%
[4]	2008	Comparison of Two ANN Methods for Classification of Spirometer Data	S. Manoharan	15 inputs, FVC, FEV1, FEF75%, PEF, Predicted Val(age, gender, race)	1 st ANN= MLP 2 nd ANN= RBF	150	3 classes: Normal, Obstructive, Restrictive RBF Networks have better accuracy compared to MLP Acc(MLP)= 96% Sen(MLP)=100% Spe(MLP)=92.6% Sen(RBF)=100% Acc(RBF)=100% Spe(RBF)=100%
[21]	2007 May	Detection of Obstructive Respiratory Abnormality Using Flow-Volume Spirometry and Radial Basis Function Neural Networks	M. Veezhinathan	Pressure, Resistance, FVC, FEV1, FEV1%, PEF, FEF25-75%, Predicted Val (age, height)	RBF	100	2 Classes: Normal, Obstructive Accuracy=90% Sensitivity=92% Specificity=88%

2-2 وضع البحث المقترح بالنسبة للدراسات السابقة

سوف ندرس استخدام خوارزميات متعددة (بعضها جديد الاستخدام في هذا المجال) لتدريب الشبكات العصبونية متعددة الطبقات MLPNNs مثل خوارزمية Levenburg Marquardt (LM) التي تتصف بسرعة التعلم وتوفير مساحة الذاكرة وزمن التدريب، وخوارزمية Bayesian Regularization (BR) و خوارزمية Resilient Back-propagation (RB) التي تتصف بالسرعة في التدريب والاستقرار في تغيير قيم الأوزان للعصبونات، بالإضافة لخوارزمية Scaled Conjugate Gradient (SCG) فيها تم التغلب على مشكلة الوقت المستهلك بإتباع خوارزمية بحث ذكية. تم تقييم كافة النتائج المستحصلة من الخوارزميات السابقة وحساب قياسات كفاءة التصنيف لها مثل الدقة والحساسية والنوعية ومساحة المنحني تحت ROC لمقارنتها بين بعضها.

سنقوم في هذا البحث دراسة كفاءة التصنيف لنظام التشخيص المتبع في جهاز وظائف الرئة (لا يعتمد على الشبكات العصبونية) حسب المعايير العالمية وتقييمها ومقارنتها مع تلك الناتجة عن الشبكات العصبونية المختلفة

سنقوم في هذا البحث أيضا دراسة إضافة معاملات جديدة يمكن أن تساعد في التصنيف بشكل إيجابي وهي تطبيق تحويل فورييه ثم حساب الطاقة الطيفية لكل من منحنى التدفق-الحجم والزمن على حدا ثم تقييم النتائج ومناقشتها ومقارنتها مع نفس الاعدادات ولكن بدون إضافة تحويل فورييه التي اقترحناها لزيادة دقة التشخيص الآلي للشبكة العصبونية المصممة.

الخلاصة:


ناقشنا في هذا الفصل عدد من الدراسات المرجعية السابقة المشابهة لبحثنا الحالي ومقارنة هذه الدراسات من حيث نوع وعدد العينات المستخدمة وأسلوب التصنيف المستخدم (نوع الشبكة العصبونية) وعدد الأصناف التي تم فرز العينات إليها بالإضافة إلى نتائج أداء التصنيف. عرضنا أيضاً وضع هذه الدراسة بالنسبة للدراسات السابقة وقمنا بتلخيص هذه النتائج ضمن جداول للمقارنة وإظهار أوجه التشابه والاختلاف بينها وبين هذه الدراسة. سنعرض في الفصل التالي جهاز وظائف الرئة وأساليب القياس المستخدمة فيه وأهم القياسات المستخدمة في تشخيص أمراض الرئة بالإضافة للحديث عن الأمراض الرئيسية للجهاز التنفسي والعلاقة بينها وبين قياسات جهاز وظائف الرئة.

الفصل الثالث

الدراسة النظرية:

جهاز اختبار وظائف الرؤية

الجهاز التنفسي هو الجهاز المسؤول عن تبادل الغازات في جميع أجزاء الجسم، حيث يقوم بتزويد خلايا الدم بالأكسجين الضروري لأنشطة جسم الإنسان، ويخلصه من ثاني أكسيد الكربون. وتعد الرئتان العضوين الرئيسيين للتنفس، وهما تركيبان مرنان داخل تجويف الصدر. تحتوي كل رئة على ملايين الأكياس أو الغرف الهوائية تسمى الأسناخ (الحويصلات)، وتوجد شبكة من الأوعية الدقيقة تسمى الشعيرات الدموية بين جدران كل حويصلة. وهناك تركيبات أخرى هامة للجهاز التنفسي، وهي جدار الصدر والحجاب الحاجز. يشتمل جدار الصدر على الضلوع التي تشكل قفصاً يحمي تجويف الصدر والعضلات التي بين الأضلاع. ويتكون الحجاب الحاجز من ملاءة من العضلات على شكل قبة تفصل بين تجويفي الصدر والبطن [26].



يتكون الجهاز التنفسي وظيفياً من:

- 1.الرئتين : وهما العضوان اللذان يتم بهما تبادل الغازات.
 - 2.المضخة التي تضخ الهواء إلى الرئتين وتتألف من :
 - 1.جدار الصدر 2.العضلات التنفسية التي تزيد وتنقص حجم الجوف الصدري. - 3.المناطق الدماغية التي تتحكم بهذه العضلات. - 4.السبل والأعصاب التي تربط بين هذه المناطق في الدماغ والعضلات.
- ويمكن أيضا تقسيم الجهاز التنفسي عند الإنسان تشريحياً كما هو موضحاً في الشكل (1-3) إلى:

1. الجهاز التنفسي العلوي (الطرق التنفسية العلوية) وتتألف من : 1.الأنف - 2.الأعضاء الملحقة بجوف الأنف - 3.البلعوم وهو طريق مشترك لكل من الجهازين الهضمي و التنفسي.
2. الجهاز التنفسي السفلي (الطرق التنفسية السفلية) وتتألف من: 1.الحنجرة - 2.الرغامى. - 3.القصبية الهوائية. - 4.الرئة.


فيزيولوجيا جهاز التنفس Physiology of Respiratory Systems:

يحتاج جسم الانسان دائماً للأوكسجين ويطرح بالمقابل غاز ثنائي أكسيد الكربون جراء قيامه بعمليات الاستقلاب الحيوي ضمن خلايا الجسم الضروري لانتاج الحرارة اللازمة لتدفئة الجسم من جهة ولتحويل الطاقة من شكل إلى آخر مفيد للقيام بأنشطة الجسم المختلفة ضمن أجهزته المتنوعة, لذلك يقوم الجهاز التنفسي بتأمين هذه الوظيفة وبالأخص الحويصلات الرئوية (الأسناخ) التي تؤمن الوسط الملائم للتبادل الغازي الآمن بين الدم (خضاب الدم) وبين هواء الوسط الخارجي الداخل للرئتين عبر الأنف, وبالتالي يحصل الانتقال الغازي بين الدم والهواء في الأسناخ حسب فرق التركيز فمثلاً يكون تركيز الأوكسجين في الدم أقل من تركيزه في الهواء وبالتالي ينتقل بدوره من الهواء للدم, وبشكل معاكس يحدث الأمر بالنسبة لثنائي أكسيد الكربون من الدم (الأعلى تركيزاً) إلى الهواء (الأقل تركيزاً).

بعد أن ينتقل الأوكسجين من الهواء للدم ويتخلص من معظم غاز ثنائي أكسيد الكربون يعبر الدم المؤكسج الدورة الدموية الرئوية (الصغرى) ثم ينتقل ماراً بالقلب إلى الدورة الدموية الكبرى ليصل إلى أماكن

استهلاك الأكسجين والتي هي الخلايا بمختلف أنواعها، عملية الاستقلاب الحيوي الحاصل على الدوام في خلايا الجسم يتطلب توفر الاكسجين (لتحويل الطاقة للشكل المفيد) وينتج عنه فضلات غازية ضارة يجب التخلص منها (وهي غاز ثنائي أكسيد الكربون) حتى لا يسبب تراكمها تراجع في كفاءة الاستقلاب ومن ثم توقفه، وطبعاً الدم وبالأخص خضاب الدم هو المسؤول أيضاً عن نقل غاز ثنائي أكسيد الكربون من أماكن تشكلها في الخلايا إلى الرئتين (الأسناخ) حيث يتم التخلص منه للهواء الخارجي.

وكما هو موضح في الشكل (2-3) نجد أنه كلما زادت مساحة (عدد وحجم) هذه الأسناخ كلما زادت كفاءة وسرعة التبادل الغازي، وكلما زادت تهوية هذه الأسناخ (زيادة تكرار الشهيق والزفير) كلما زادت كفاءة وسرعة التبادل الغازي. وكما هو ملاحظ في الشكل أن زيادة النشاط العضلي يتطلب زيادة في استهلاك الاوكسجين والذي بدوره يستلزم زيادة في ضخ الدم من قبل القلب وزيادة التهوية الرئوية (شهيق وزفير) وإلا سوف يتعرض الجسم للتعب السريع.



2-3 جهاز اختبار وظائف الرئة (Pulmonary Function Test (PFT):


لنتمكن من الحصول على البيانات الكافية لتقييم حالة الجهاز التنفسي عند شخص مصاب أو سليم لا بد من وسيلة معيارية قادرة على قياس معاملات محددة لوظيفة الرئة المتمثلة في انجاز عملية التنفس من خلال تأمين الأوكسجين للجسم وطرح غاز ثنائي أكسيد الكربون بشكل طبيعي متناسب مع حاجة الجسم في مختلف حالاته: في العمل أو الراحة. لهذا الهدف تم الاستعانة بجهاز قياس التنفس Spirometer لقياس هذه المعاملات، هذا الجهاز تم تطويره وتزويده بكافة الخيارات اللازمة لإجراء فحوصات وظيفة الرئتين وتمت تسميته بجهاز فحص وظيفة الرئة Pulmonary Function Test (PFT) وهو النوع المستخدم في مشروعنا الحالي.

فيما يلي سوف نعرف جهاز وظائف الرئة ونشرح المعاملات الشهيرة التي يقيسها الجهاز.

تعريف: جهاز فحص وظيفة الرئة PFT: هو نظام تقييم أداء وظيفة الرئة التنفسية من خلال تطبيق مجموعة إجراءات فحص على المريض تتضمن قياسات للحجوم والتدفقات والأزمنة المحددة للرئة أثناء قيامها بعملية التنفس وفق بروتوكولات متفق عليها، وبالحصول على قيم هذه القياسات أصبح بمقدورنا الكشف عن أمراض تتعلق بـ: (1 تضيق في المجاري التنفسية أو (2 قصور في حجم الرئة أو (3 انخفاض في تبادل الغازات عبر أغشية الشعيرات الدموية، وبالتالي إذا كانت قيم القياسات الناتجة خارج المجال المسموح به وفق حسابات وإحصائيات القيم الطبيعية الناتجة عن عمر المريض وجنسه ووزنه وطوله دل ذلك على وجود علة مرضية تقتضي المعالجة [6, 7]. يبين الملحق الرابع الأجزاء الرئيسية لجهاز اختبار وظائف الرئة ومخطط صندوقي مبسط لأهم المكونات الأساسية فيه [7].


طريقة القياس:

يعتمد قياس الجهاز للحجوم والسعات على عنفة تتكون من شفرات دوارة حول محور متركز لأنبوب يتنفس منه المريض (شهيق-زفير) تدور الشفرات بسرعة متناسبة مع التدفق وبعدد دورات متناسب مع الحجم لنتم ملاحظة هذه الدورات بزوجين من مرسل-مستقبل أشعة تحت الحمراء IR الشكل (3-3) [7].



يبين الملحق الرابع مواصفات العنفة الهوائية المستخدمة في القياس والتقنية المستخدمة في استحصال إشارة الحجم والتدفق باستخدام تقنية (مرسل-مستقبل) ضوئي [7].

ويبين الشكل (4-3) تخطيطاً لحجوم وسعات الرئة الذي يساعد في تقييم وكشف الاعتلالات المرضية في الرئة [6]:



وفيما يلي تعريف لأهم القياسات الموجودة في مخطط الحجم والسعات المذكور في الشكل (3-4)، تقاس هذه الحجم بوحدة الليتر (L) [6]:

1- Tidal Volume (TV/V_t): الحجم المدي هو حجم الهواء الداخل والخارج للرئة في حالة التنفس الطبيعي (راحة).

2- Inspiratory Reserve Volume (IRV): حجم احتياطي الشهيق هو حجم أكبر كمية من الهواء يمكن للشخص إدخالها للرئتين بدءاً من مستوى الحجم المدي.

3- Expiratory Reserve Volume (ERV): حجم احتياطي الزفير هو حجم أكبر كمية من الهواء يمكن إخراجها من الرئتين بدءاً من مستوى الحجم المدي.

4- Residual Volume (RV): الحجم المتبقي هو حجم الهواء داخل الرئة متضمناً المجاري التنفسية والحوصلات الرئوية ولا يمكن إخراجها من الرئة بعد الزفير القسري، ولا يتم قياسه بالطرق المباشرة بل بطرق غير مباشرة [6].

ماسبق ذكره من مصطلحات هو حجوم للرئة يتم قياسها مباشرة، بينما ينتج عن جمع هذه الحجم السعات وتقاس الحجم والسعات بوحدة الليتر (L):

1- Inspiratory Capacity (IC): سعة الشهيق هو مجموع $TV + IRV$.

2- Functional Residual Capacity (FRC): السعة المتبقية الوظيفية هي $RV + ERV$ وهو حجم الهواء المتبقي داخل الرئة بعد الزفير الطبيعي (نهاية الحجم المدي) وغالباً ما يكون حوالي 40% من TLC.

3- Vital Capacity (VC): السعة الحيوية هي $IRV + TV + ERV$ وتعتبر عن أكبر كمية من الهواء يمكن إخراجها ابتداءً من سوية شهيق أعظمي وصولاً للزفير الأعظمي.

4- Total Lung Capacity (TLC): السعة الكلية للرئة هي مجموع كافة الحجم المقاسة: $IRV + TV + ERV + RV$ [6].

نشرح في الفقرة التالية الأمراض الشهيرة للرئة و علاقتها بالقياسات التي يقدمها جهاز فحص وظيفة الرئة، و ذلك من أجل استكمال جميع جوانب هذه الدراسة.

3-3 أمراض الرئة والعلاقة مع قياسات اختبار جهاز وظائف الرئة PFT

3-3-1 مقدمة عن أمراض الرئة وأسبابها المباشرة:

إن تلوث الهواء الحاصل في طبقات الجو الناتج عن ازدهار الصناعات واستخدام الآليات بشكل واسع علاوة على انتشار عادة التدخين وغيرها من العوامل الكثيرة التي تغير من تركيب الغازات التي يتنفسها الإنسان أوجد ضرورة الاهتمام بفحص الوظيفة الرئوية للناس الذين يقطنون في مناطق قريبة من المدن الصناعية بشكل عام والعاملين بشكل خاص الذين هم دائماً على تماس مباشر مع مظاهر التلوث، يساعد الفحص الدوري للعاملين مثلاً بالكشف المبكر عن أمراض الرئة مما يساعد على العلاج السريع والسهل للمرض لأنه في مراحله الأولية وإضافة لإمكانية مراقبة فعالية أساليب وأدوية العلاج المطبقة على المريض. ويمكن أن نذكر بعض أمراض الرئة الشائعة (تحتوي الفقرة 3-3-2 شرح لمصطلحات FVC, FEV_1 والنسبة FVC/FEV_1):

(1) مرض ذات الرئة التضيقية المزمن (Chronic Obstructive Pulmonary Disease (COPD): وهو عدم القدرة على إخراج الهواء من الرئة حيث تكون المجاري الهوائية متضيقية مسببة في الغالب زيادة في زمن الزفير (إفراغ الرئة من الهواء) مما يسبب نقص في التدفق وقيمة FEV_1 . يمكن أن تحدث أمراض الرئة التضيقية في ظروف مثل انتفاخ الرئة Emphysema، التهاب الشعبى Bronchitis، الربو Asthma، وغالباً ما يترافق هذا المرض بانخفاض في النسبة FEV_1/FVC [2]. وهناك أيضاً مرض تضيق المجاري الهوائية العكسي كما في الربو يسبب زيادة في FEV_1 بنسبة 12%. والجدير بالذكر أن إجمالي وفيات هذا المرض وصلت 5% من إجمالي الوفيات العالمية حسب احصائيات عام 2005 [6].

(2) حالات قصور الرئة Restrictive Lung: هو عدم القدرة على إدخال الهواء للرئتين ويمكن أن يعرف بشكل أفضل بانخفاض في سعة الرئة الإجمالي حيث يكون هنالك خسارة في أنسجة الرئة أو نقص في قدرة الرئة على الاتساع أو نقص في قدرة الرئة على نقل الأوكسجين إلى الدم أو ثنائي أكسيد الكربون من الدم، يحتمل وجوده عندما تنخفض قيمة FVC وتدفق زفير عالي وتكون نسبة FEV_1/FVC طبيعية. يمكن أن تحصل أمراض الرئة القاصرة في حالات مثل التهاب

الرئوي Pneumonia, سرطان الرئة, التليف الرئوي Pulmonary Fibrosis, ساركويدوسيز Sarcoidosis أو تصلب أنسجة متعدد Multiple Sclerosis [2, 6].

(3) حالات مختلطة Mixed بين النوعين التضيقى والقصور: تنقص قيمة كل من الحجم والتدفق ولكن نقصان الحجم يكون أكبر من التدفق وبالتالي تنقص كل من قيمتي FEV₁, FVC وتزداد النسبة FEV₁/FVC.

(4) أمراض الأوعية الرئوية Pulmonary Vascular Disease (PVD): تتعلق هذه الأمراض بعناصر الدورة الدموية الرئوية مثل التهاب الوعائي Vasculitis أو ارتفاع الضغط الشرياني الرئوي Pulmonary Artery Hypertension. غالباً ما يتم الاشتباه بوجود هذه الأمراض باختبار فعالية التبادل الغازي للحويصلات الرئوية ومساحة سطح التبادل الداخلي والمعروف باختبار DLco Co Diffusing Capacity, والجدير بالذكر أنه ممكن أن تكون كافة المعاملات السابقة ضمن الحدود الطبيعية ولكن حدود قيمة DLco تكون أدنى من الحد الطبيعي المسموح [6].

3-3-2 العلاقة بين قياسات مخطط التنفس وأمراض الرئة:

عند قراءة تقرير فحص وظيفة الرئة يمكن أن نصادف بعض القياسات الجديدة والتي هي غالباً مشتقة من القياسات السابقة الأساسية المحددة للرئة وقبل البدء بذكرها لا بد من التعرف على المصطلح التالي:

❖ طريقة السعة الحيوية القسرية Forced Vital Capacity لحساب الحجوم والسعات يعتمد هذا الأسلوب على قيام المريض في البداية بالتنفس الطبيعي في حالة الراحة لحساب الحجم المدي V_t ثم استنشاق أكبر كمية هواء ممكنة وبعدها إخراج كامل الهواء داخل الرئة بأقصى سرعة ممكنة ولمدة زمنية لا تقل عن 5~6 ثوانٍ , لضمان دقة عملية القياس وهو نفسه السعة الحيوية للرئة VC, في هذه الإجرائية نكون قادرين على حساب كافة الحجوم المحددة للرئة بدقة ما عدا RV [8].

وفيما يلي تعريف ببعض القياسات الأساسية في تقرير اختبار وظيفة الرئة والمذكورة في الأشكال (3-6) و(3-7) والجدول (3-2) [6,9,24]:

1- Forced Vital Capacity (FVC): السعة الحيوية القسرية والذي يمثل أكبر حجم للهواء الداخل والخارج للرئة عند تنفس المريض بشكل إجباري حيث يتم انجاز شهيق أعظمي يليه مباشرة زفير أعظمي، وتقاس بوحدة اللتر (L).

2- FEV₁ (First second of Expiration Volume): هو حجم هواء الزفير خلال الثانية الأولى من اختبار FVC. ورغم أن هذا القياس هو حجم إلا أنه يحوي معلومات عن التدفق أو حدوث التضيق لأن حجم مقاس خلال نطاق زمني ثابت، يتعلق كذلك بـ TLC، يقاس بوحدة اللتر (L).

3- FEV₁/FVC: يفيد هذا المعدل في تقييم التضيق الحاصل في المجاري التنفسية وهو مستقل عن حجم ووزن المريض وعندما يكون هذا المعدل أقل من 75% عندها يشتبه وجود تضيق أو حالة طبيعية وإذا كان مساوياً أو أكبر من 75% يشتبه على وجود قصور، وليس له وحدة.

4- تدفق الزفير القسري (Forced Expiratory Flow) FEF: غالباً ما يتم استنتاجه من تقسيم الفروقات الحجمية على الفروقات الزمنية وذلك عند النقاط التالية: 25%, 50%, 75% من زمن اختبار FVC، وتقاس بالليتر/الثانية (L/s).

5- تدفق الزفير الأعظمي (Peak Expiratory Flow) PEF: هو أكبر تدفق يمكن أن يحصل خلال اختبار FVC، وتقاس بالليتر/الثانية (L/s).

يبين الجدول (1-3) العلاقة بين الأمراض المذكورة سابقاً مع قيم القياسات التي نحصل عليها من تقرير فحص وظيفة الرئة التنفسية [6]. على سبيل المثال في حال الإصابة بمرض انسدادى مثل الربو Asthma وذات الرئة المزمن COPD تكون قياسات الـ FVC و TLC و RV/TLC أعلى من قيمتها في الحالة السليمة أو نفسها بينما تكون قيم قياس الـ FEV₁ أخفض من قيمته في الحالة السليمة، أما قيم قياسات النسبة المئوية FEV₁/FVC=FEV₁% فيجب أن تكون أقل من القيمة 75% وبالتالي حتى نتأكد من تمييز هذين المرضين الانسداديين عن بعضهما نلجأ لقياس إضافي هو DLco الذي يكون في حالة مرض الربو Asthma ضمن حدود الحالة السليمة في حين يكون في حالة مرض ذات الرئة COPD أخفض من قيمته في الحالة السليمة.

الجدول (3-1) بعض أمراض الرئة الشائعة وعلاقتها بقياسات جهاز فحص الوظيفة الرئوية، مأخوذ عن [6].


مرض رئة حاصر Restrictive		مرض رئة ساد Obstructive		
انتفاخ الصدر Chest Bellows	مرض بارانشيمي Parenchymal	مرض COPD	مرض الربو	
D	D	N or I	N or I	FVC
D	D	D	D	FEV₁
75%<=	75%<=	75%>	75%>	FEV₁/FVC
D	D	N or I	N or I	TLC
I	N	N or I	N or I	RV/TLC
N	N	I	I	Airway resistanc
N	D	D	NI	DLco
D: decreased (انخفاض), I: increased (ارتفاع), N: normal (حدود طبيعية)				

مرض Asthma	مرض CHF	مرض PVD	مرض IPF	مرض COPD	الحالة الطبيعية	
N or ↑	N or ↓	N	↓	N or ↓	N	FVC
↓	N or ↓	N	↓	↓↓	N	FEV₁
N	↓	↓	↓↓	↓	N	DLco

**COPD= chronic obstructive pulmonary disease; IPF= idiopathic pulmonary fibrosis;
PVD= pulmonary vascular disease; CHF= chronic heart failure, N=normal**

3-4 معايير التشخيص العالمية لأمراض الجهاز التنفسي ETS/ERS:

بعد أن تعرفنا على القياسات الهامة في تشخيص وظيفة الجهاز التنفسي يمكننا الحديث عن استراتيجية التشخيص المتبعة في معايير عالمية مختصة في أمراض الجهاز التنفسي وفحوصات تقييم فعالية وظيفة الجهاز التنفسي مثل الجمعية الأمريكية لأمراض الصدر (ATS) American Thoracic Society و الجمعية الأوروبية لأمراض التنفس (ERS) European Respiratory Society كما هو معروض في الشكل (3-6) [8]:



الشكل (3-5) الاستراتيجية المتبعة في تشخيص أمراض الجهاز التنفسي وفق معايير ATS/ERS, حيث أن LLN هو السوية الدنيا الطبيعية التي يمكن أن نقارن بها قيمة كل قياس مقاسة (تم الحصول عليه من الإختبار) مع القيمة المتنبأ بها المحسوبة باعتبار جنس المريض وطوله ووزنه وسلالته, حيث أن CB Chronic Bronchitis هو مرض التهاب الشعبى الحاد و NM Neuromuscular هواعتلال عضلي عصبي في الرئة و CW Chest Wall هواعتلال في جدار الصدر وILD Interstitial Lung Disease هو مرض التهاب في التركيبة الخلالية للرئة, مأخوذ عن [8].

وهناك خطوات أساسية في تشخيص الحالات الانسدادية والقصور من تقرير وظائف الرئة [6,8] موصى بها من قبل الأطباء المتخصصين حسب المعايير والاستراتيجية المعروضة مسبقاً في الشكل (3-5):

1- الخطوة الأولى: التأكد من قيمة السعة الحيوية القسرية FVC إذا كانت ضمن الحدود الطبيعية.

2- الخطوة الثانية: التأكد من قيمة حجم الزفير القسري خلال الثانية الأولى FEV₁ إذا كانت ضمن الحدود الطبيعية.

3- الخطوة الثالثة: إذا كانت كلا القيمتين FVC و FEV_1 طبيعية عندها ليس من الضروري التأكد من قيم قياسات أخرى في الفحص لأن تقرير فحص PFT للمريض طبيعي.

4- الخطوة الرابعة: إذا كانت القيمة FVC و/أو قيمة FEV_1 منخفضة عندها من المرجح بدرجة كبيرة وجود علة مرضية عند الشخص.

5- الخطوة الخامسة: إذا تحدد من الخطوة الرابعة وجود علة مرضية ينبغي عندها التأكد من القيم المتنبأ بها للمريض predicted % (حسب عمره وطوله ووزنه و...) للنسبة FEV_1/FVC . إذا كانت هذه القيمة مساوية لـ 80~90% أو أعلى عندها من المحتمل أن المريض يعاني من مرض قصور رئة (Restricted lung)، أما إذا كانت هذه القيمة مساوية لـ 69% أو أقل عندها من المحتمل أن المريض يعاني من مريض انسداد في الرئة (Obstructed Lung).

كما أن هنالك استراتيجية متبعة بين الأطباء في تشخيص أمراض الجهاز التنفسي للتشخيص باستخدام جهاز وظائف الرئة وبخاصة للتفريق بين الأمراض السادة والأمراض الحاصرة (على الرغم أن المعلومات التالية هي معلومات سريرية بحتة فقد تم إضافتها لاستكمال هذه الأطروحة للباحثين المهتمين بهذا الموضوع). تتضمن هذه الاستراتيجية الخطوات التالية [25]:

1- انظر إلى قيمة Pred. % للقياس FVC (والتي هي القيمة المقيسة للقياس على القيمة المتنبأ بها للقياس $100 \times$)، إذا كانت هذه القيمة ضمن الحدود الطبيعية وهي (80 ~ 120%).

2- انظر إلى قيمة Pred. % للقياس FEV_1 (حجم الزفير القسري خلال الثانية الأولى من الزفير) إذا كانت ضمن الحدود الطبيعية المسموح بها وهي (80 ~ 120%).

3- إذا كانت كلا القيمتين طبيعيتين عندها لا داعي للتحقق من بقية القياسات و عندئذ الحالة طبيعية.

4- إذا كانت كلا أو أحد القيمتين السابقتين منخفض أي أقل من 80% دل ذلك على وجود علة مرضية.

في حالة تحقق الشرط 4 يجب عندها التحقق من قيمة $\%Pred.$ للقياس $FEV1/FVC$, إذا كانت هذه القيمة تحقق نسبة ($88 \sim 90\%$) أو أعلى فالمريض يعاني من مرض رئة حاصرة Restrictive Disorder, وإذا كانت هذه القيمة تحقق نسبة 69% أو أقل فالمريض من مرض رئة سادة Obstructive Disorder.

ملاحظات هامة:

- بشكل عام إن تفسير اختبار التنفس للمريض يبدأ بشكل أساسي بالتفريق بين الحالات السادة Obstructive وبين حالات القصور Restrictive وبالتالي حتى نتمكن من التفريق بين الحالتين الرئيسيتين يجب أن نعرض التعاريف التالية حسب ATS:
- يتم تعريف تضيق الطرف الهوائية على أنه انخفاض غير متناسب في التدفق الهوائي بشكل إجمالي بالاعتماد على الحجم الإجمالي للهواء الذي يخرج المريض من الرئة. وبالتالي فإن انخفاض النسبة $FEV1/FVC$ عن (75%) يدل على علة سادة.
- يتم استخدام قيمة $FEV1$ والقياسات الأخرى عادة بالمقارنة مع القيم المتنبأ بها الموافقة لتحديد حدية المرض (Mild, Moderate, Severe, Very Severe).
- يتم استخدام قيمة $FEF 25\% \sim 75\%$ التي تعبر عن متوسط معدل التدفق الزفير كقيمة حساسة ولكنها غير محددة لانسداد الطرق الهوائية ولكن إذا انخفض تدفق الشهيق عن تدفق الزفير عندها يمكن أن نستدل على وجود انسداد طرق هوائية علوي.

3-5 مخططات اختبار FVC المستحصل بجهاز PFT وأمثلة مرضية

اعتماداً على اختبار السعة الحيوية القسرية FVC في تشخيص أمراض الجهاز التنفسي لعينات المرضى, فإنه من الممكن تصنيف أربعة حالات رئيسية هي:

- 1- حالة طبيعية Normal.
- 2- حالة مرضية سادة Obstructive Abnormality.
- 3- حالة مرضية حاصرة Restrictive Abnormality.

4- حالة مزدوجة بين الحاصرة والسادة Mixed Obstructive & Restrictive Abnormality.


بالتالي يوفر لنا اختبار FVC ثلاثة مخرجات هي:

- 1) قياسات تشخيصية عديدة (حوالي 10 أو أكثر) يتم حسابها مباشرة بواسطة برنامج الجهاز ويرفق مع كل قياس قيمة متنبأ بها لهذا القياس وفق الجدول (2-3):

الجدول (2-3) عرض مثال لقيم القياسات الناتجة عن اختبار السعة الحيوية للرئة FVC, يوضح العمود الأول Parameter اسم القياس, العمود الثاني UM وحدة القياس المعيارية الخاصة بالقياس


Parameter	UM	Description	Pred.	BEST#1	%Pred.
Best FVC	l(btps)	Best Forced Vital Capacity	3.14	3.47	110.3
FVC	l(btps)	Forced Vital Capacity	3.14	3.47	110.3
FEV1	l(btps)	Forced Exp Volume in 1 sec	2.52	2.79	110.6
PEF	l/sec	Peak Expiratory Flow	7.21	9.40	130.3
FEV1/FVC%	%	FEV1 as % of FVC	76.4	80.4	105.3
FEF25-75%	l/sec	Forced mid-expiratory flow	3.17	2.62	82.7
MEF75%	l/sec	Max Exp Flow @ 25% FVC	6.36	7.73	121.4
MEF50%	l/sec	Max Exp Flow @ 50% FVC	3.74	3.38	90.5
MEF25%	l/sec	Max Exp Flow @ 75% FVC	1.20	0.98	81.7
FET100%	sec	Forced Expiratory Time		5.8	
PEFr	l/min	Peak Expiratory Flow (l/min)	432.6	563.8	130.3
Diagnosis:					
Normal Spirometry					
Printed 01/03/2012					
PFT Suite 9.1b					
Page 1 of 1					

- 2) مخطط الحجم مع الزمن الذي يمكن نتأكد منه أن المريض قد أنجز الزفير القسري الأعظمي للفترة الزمنية الموصى بها عالمياً (حسب معايير ATS/ERS حوالي 6 ثواني على الأقل) كما يمكن قراءة السعة الحيوية القسرية FVC مباشرة من محور الحجم, وبالتالي دوره الأساسي في تحديد جودة أداء الاختبار كما في الشكل (3-6):



(3) مخطط التدفق مع الحجم يفيد الطبيب في التأكد من إنجاز المريض لكامل إجرائية الاختبار بدءاً من التنفس الطبيعي في حالة الراحة slow vital capacity ثم الشهيق القسري الأعظمي يليه مباشرة الزفير القسري الأعظمي كما هو موضح في الشكل (7-3)، لذلك حتى يتم اعتماد تقرير الفحص بالنسبة للطبيب يجب أن يطبق الإجراء حسب المعايير والتي ترسم منحنى مألوف بالنسبة للطبيب (من ناحية إغلاق الحلقة التنفسية) لأنه هو الممثل للإجراء الصحيح، كما أن الطبيب من ناحية أخرى يمكن أن يكشف وجود العلة المرضية من شكل المنحنى: هل هو علة سادة أو حاصرة أو مختلطة أو طبيعية، ولكن تبقى القياسات في الجدول (2-3) هي الأساسية في اتخاذ القرار.

يشرح الشكلين (8-3) ، (9-3) منحنى تغيير التدفق مع الحجم وتغير الحجم مع الزمن على الترتيب خلال التنفس وفق اختبار السعة الحيوية القسرية FVC الوارد في الشكل (6-3)، (7-3) على الترتيب موضحاً الحالات المرضية واختلاف المنحنى حسب الحالة المرضية للشخص المصاب أو السليم [6].



الخلاصة:

تضمن هذا الفصل دراسة نظرية لجهاز وظائف الرئة المستخدم في المساعدة في تشخيص أمراض الجهاز التنفسي، حيث عرضنا لمحة عن الأجزاء الأساسية للجهاز التنفسي وآلية التنفس. تحدثنا أيضاً عن مبدأ عمل جهاز وظائف الرئة وأساليب القياس فيه وأهم القياسات التي تنتج عنه والمستخدمه تقييم وظيفة الجهاز التنفسي. بالإضافة إلى ذلك عرضنا الأصناف الأساسية لأمراض الرئة والعلاقة بينها وبين قياسات الجهاز وكيفية الاستدلال على وجود الحالات المرضية من قراءة قياسات ومخططات الجهاز. وأخيراً ذكرنا بعض الأمثلة عن مخططات للحالات المرضية والسليمة. سنعرض في الفصل التالي دراسة نظرية عن أساليب الذكاء الصناعي المستخدمة للمساعدة في التشخيص الطبي والتي منها الشبكات العصبونية، حيث سنتعرف على أنواع الشبكات العصبونية وكيفية بنائها واختيار معاملاتها وفحصها وتقييم نتائجها.

الفصل الرابع

الدراسة النظرية:

الشبكات العصبونية وتطبيقاتها

1-4 أساليب التشخيص المحوسب الطبي Medical Computerized Diagnosis

يمكن أن نعرف التشخيص المحوسب ببساطة بأنه استخدام الحاسب في عمليات التشخيص الطبي للمساعدة في اتخاذ القرار التشخيصي بشكل أكثر فعالية وسهولة وسرعة لأخصائي التشخيص (الطبيب أو الممرض). نذكر من أساليب التشخيص المحوسب ما يلي:

1. الأنظمة الخبيرة Expert Systems.
2. أساليب الذكاء الصناعي Artificial Intelligence: ونذكر منها الأنواع التالية:
 - 1- الشبكات العصبونية الصناعية Artificial Neural Network.
 - 2- الخوارزميات الجينية Genetic Algorithm.
 - 3- الأنظمة الضبابية Fuzzy Systems.
 - 4- نظرية المجموعة غير المنتظمة Rough Set Theory.

1-1-4 الأنظمة الخبيرة Expert Systems

هو برنامج حاسوبي غزير المعرفة ينمذج خبرة الانسان لنطاق معرفة معين. والنظام الخبير الطبي هو نظام متخصص من ناحية طبية بمرض معين أو لمهمة معينة في التشخيص السريري يتضمن قواعد معرفة طبية في هذا المجال كافية لاستنتاج التشخيص من البيانات الخاصة بكل مريض على حدا. ويمكن أن تستخدم الأنظمة الخبيرة في نواحي طبية عديدة نذكر منها:

- 1- المساعدة التشخيصية Diagnostic Assistance.
- 2- نظام المعلومات المخبري الخبير Expert Laboratory Information System.
- 3- التخطيط والاقتراح العلاجي Therapy Critiquing and Planning.
- 4- تمييز وتفسير الصور الطبية Medical Image Recognition and Interpretation.

ونذكر بعض الأمثلة على هذه البرامج:

- (1) برنامج أمراض القلب (HDP) Heart Disease Program.
- (2) نظام الوظيفة الرئوية (PUFF) Pulmonary Function System.

4-1-2 أساليب الذكاء الصناعي (AI) Artificial Intelligence

هي إعطاء الحاسب أو البرنامج القدرة على تقليد عمل الانسان بالعمليات التي تتطلب ذكاء مثل التعلم والاستنتاج من التدريب والخبرة والتجارب [10].

يمكن أن نقسم علم دراسة الذكاء الصناعي إلى مستويين رئيسيين هما:

(1) الذكاء الصناعي الترميزي التقليدي Symbolic AI: الذي يبحث في المستوى التجريدي أو الفلسفي البحث ويدعى أيضاً بالنظرة العيانية Macroscopic View, ويشمل أنظمة قواعد المعرفة, الاستنتاج المنطقي, تعليم الآلة الرمزي, تقنيات البحث ومعالجة اللغة الطبيعية.

(2) الذكاء الصناعي البنائي العملي: يبحث في تفاصيل أساليب الذكاء الصناعي من الناحية المادية التصميمية ويدعى أيضاً بالنظرة المجهرية Microscopic View, ويشمل الشبكات العصبونية Artificial Neural Networks والخوارزميات الجينية Genetic Algorithms.

(3) تقنيات حديثة للذكاء الصناعي:

1- Fuzzy Systems: حيث تتعامل مع بيانات غير عددية وتكون غير مكتملة أو دقيقة في معظم الحالات, وبالتالي تتيح لنا هذه الأنظمة قدراً وافراً من محاكاة الحياة الواقعية بدرجات مختلفة.

2- Rough Set Theory: إحدى تقنيات التكميم أو التخطيط وهي تعني مجموعات تقريب approximation sets تعطي عناصر وقيم ميزات متعلقة بهذه العناصر, ويمكن أن تكون ناقصة غير دقيقة, وتفيد هذه النظرية في استنتاج واكتشاف العلاقات في بيانات معينة.

3- خوارزميات البحث الذكية.

4- نظرية التعلم Learning Theory.

في الفقرات التالية سوف يتم التركيز في الشرح على الشبكات العصبونية بشكل موسع لأنها النوع المستخدم في الدراسة.

3-1-4 الشبكات العصبونية الصناعية (ANN) Artificial Neural Networks

1-3-1-4 مقدمة: تم العمل على تطوير الشبكات العصبونية وتقنيات الذكاء الصناعي بشكل أساسي في مطلع الستينيات ومنتصف الثمانينيات وقد كانت مفتاح تطوير حقل تعلم الآلة. تم استيعاء فكرة الشبكات العصبونية الصناعية من الاكتشافات العلمية المتعلقة بالدماغ البشري حيث تم تسمية شبكة الوحدات المكونة للدماغ بالعصبونات Neurons حيث يمكن أن يبلغ عددها حوالي 10^{12} عصبون (خلية عصبية). كل عصبون من هذه العصبونات في الشبكة المكونة للدماغ يتصل بالآخر بروابط اتصال يمكن أن يصل عددها بشكل وسطيّاً بحوالي 10^{16} رابط تدعى المشابك العصبية. كل عصبون يستقبل إشارات عن طريق هذه المشابك والتي تتحكم بتأثير الإشارات على العصبونات الأخرى المتصلة بها.

2-3-1-4 ميزات استخدام الشبكات العصبونية

بشكل عام كانت محاسن الشبكات العصبونية ومرونتها من أولى الأسباب التي دفعتنا لاستخدامها في هذه الدراسة ونذكر منها [9]:

- (1) قابليتها للتعلم من التجربة والتدريب: على الرغم من تعقيد المشكلة المطروحة فهي تستفيد من كمية البيانات المتاحة التي تصف المشكلة وتقبل بقدر من التسامح في الأخطاء (Tolerance).
- (2) قدرتها على التعميم بعد انجاز عملية التدريب من أجل البيانات غير المدخلة مسبقاً وذلك وفق التعلم السابق وهو ما يعرف بالتعميم.
- (3) التطوير السريع للتطبيقات.
- (4) الوثوقية ومثانة التصميم Robust: تتمتع الشبكات العصبونية بوثوقية أعلى مقارنة مع أساليب الذكاء الصناعي الأخرى، حيث أنها تملك قدرة عالية في التعامل مع البيانات غير المكتملة أو المشوشة.
- (5) التكيف مع متغيرات البيئة الواقعية.
- (6) كفاءة حسابية عالية: على الرغم أنها تحتاج لقدرة حسابية عالية في مرحلة التطبيق لكن الشبكات المدربة تبدي سرعة عالية في الاستجابة.

(7) اللاخطية: لا تعتمد على الافتراضات الخطية المتواجدة في العالم الحقيقي لأنها عناصر حسابية عالية التوزع وفق أنظمة تفرعية Highly Parallel Distributed Systems.

يوجد للشبكات العصبونية الصناعية ANN مساوئ نذكر منها:

- (1) غالباً ما تعتبر الشبكات العصبونية كصندوق أسود Black Box.
- (2) عدم القدرة على قيادة المشروع: غالباً ما يكون الوقت والمصادر اللازمة للوصول إلى النتائج المرجوة من المشروع غير قابلة للتنبؤ الدقيق وغير متوقعة، وهذا ما يستلزم تحليل دقيق للمشروع وجمع أكبر كمية من البيانات الممثلة للمشكلة المطروحة.
- (3) من غير الممكن عادة تعيين الحل الكامل للمشكلة المطروحة خلال مرحلة التصميم: لذلك من المهم في البداية بناء نموذج أولي للمشروع وإجراء التجارب عليه وإيجاد الحل المناسب لها.
- (4) الأداء أهم من سرعة العملية: حيث يتوجب الانتباه لمشاكل الأداء بشكل حذر عند تحليل المتطلبات والتصميم ومرحلة الاختبار للشبكة.

4-3-1-3 أسلوب التعلم في الشبكات العصبونية

قبل البدء بالحديث عن خوارزمية التدريب لابد من تعريف عملية التدريب ووظيفتها، عملية التدريب هي آلية لتعديل قيم الأوزان التي تصل بين العصبونات بشكل يتحقق في أفضل تطابق بين الخرج الفعلي والهدف المطلوب الوصول إليه، وبالتالي فإن عملية التعلم هي قدرة الشبكة العصبونية على اتخاذ قرار بنسبة صحة مقبولة من أجل عينات محددة بعد إنجاز عملية التدريب الكافية على عينات مجموعة التدريب، ولا يكفي أن تمتلك الشبكة قدرة على إتخاذ هذا القرار من أجل العينات التي تم التدرب عليها بل يجب أن تكون قادرة على إتخاذ هذا القرار بنسبة صحة مقبولة من أجل العينات التي لم تتدرب عليها من قبل وهذا ما يعرف بالتعميم. إن خوارزمية التدريب المستخدمة في هذا البحث والتي هي خوارزمية الانتشار التراجعي Back-Propagation Algorithm (BP) تعمل على تعديل الأوزان بين العصبونات بعد حساب الخطأ الحاصل بين الخرج والهدف بشكل تراجعي أي بدءاً من عصبونات طبقة الخرج حتى عصبونات طبقة الدخل بهدف تقليل نسبة الخطأ هذه إلى أقصى حد ممكن. لذلك لابد من تعريف مقياس لحساب الخطأ الذي تقوم به الشبكة E [1,10] ومن الممكن أن يكون وفق المعادلة (4-1):

$$MSE = E = (t - A)^2 \quad (1 - 4)$$

الذي يعرف بمتوسط مربع الخطأ Mean Square Error (MSE) كما أنه يمكن أن يكون حسب المعادلة

(2-4) والذي يعرف بجذر متوسط مربع الخطأ (Root Mean Square Error (RMSE):


$$RMSE = E = \sqrt{(t - A)} \quad (2 - 4)$$

حيث تمثل t خرج الشبكة المطلوب (الهدف) و A هو الخرج الفعلي في شبكة المستقبلات متعددة الطبقات MLP و E هو الخطأ. تعتمد خوارزمية الانتشار الخلفي BP على إيجاد النهاية الصغرى لتابع الخطأ التي يتم حسابها وفق خوارزمية الانحدار المتدرج Gradient Descent كما في المعادلة (3-4):

$$\Delta\omega_{ij} = -\mu \frac{\partial E_q}{\partial \omega_{ij}} \quad (3 - 4)$$

يطلق على هذه المعادلة بالشكل العام لقاعدة دلتا "Generalized Delta Rule" حيث أن $\Delta\omega_{ij}$ هو التغيير في وزن الاتصال من العصبون z إلى العصبون i , و ∂E هو التغيير في قيمة تابع الخطأ الكلي لكل العصبونات في الطبقات من أجل الدخل q , μ هو معدل التعلم الذي يمكن أن يكون لكل الطبقات أو لكل طبقة على حدا وغالباً يفضل أن يكون ذو قيمة صغير في البداية لضمان حدوث تعديل صغير في الأوزان وبالتالي حدوث تقارب للتابع بشكل تدريجي لتلافي حدوث مشاكل في تحديد النهاية المطلوبة.

يوضح الشكل (1-4) عملية تعديل الأوزان التي تتم بشكل عكسي من الخرج للدخل [10]:



الشكل (1-4) أسلوب عمل خوارزمية الانتشار الخلفي لتابع الخطأ في عصبونات في الشبكة المتعددة الطبقات MLP (طبقتين), مأخوذ عن [10]

من الناحية الرياضية يمكن تعريف هذه الخوارزمية على أنها تعميم لقاعدة التعلم Widrow-Hoff (أو المعروفة أيضاً بخوارزمية Least Mean Squares Algorithm (LMS)) بشكل يتلائم مع الشبكات العصبونية متعددة الطبقات وتوابع التحويل التفاضلية غير الخطية، حيث أنها تعتمد على خوارزمية الانحدار المتدرج Gradient Descent Algorithm والتي فيها عملية التعديل بالأوزان والانزياحات للعصبونات في الشبكة تتحرك بعكس ميل أو تدرج تابع الأداء Performance Function (المحدد لقيمة الخطأ الحاصل بين الدخل والهدف)، أما حساب الانحدار في التدرج Gradient Descent فيتم بواسطة عدة خوارزميات تعتمد في أسلوبها على تقنيات الوصول للقيم المثلى Optimization Techniques، وفيما يلي شكل للمعادلة الأساسية لتعديل الأوزان والانزياحات وفق هذه الخوارزمية في الشبكات نوع MLP تم إستنتاجها من المعادلة (3-4) وقاعدة شين Chain Rule للاشتقاق الجزئي الموضحة بالمعادلة (4-4):

$$\Delta\omega_{ij} = -\mu \frac{\partial E_q}{\partial v_j} \frac{\partial v_j}{\partial \omega_{ij}} \quad (4 - 4)$$

حيث أن $\frac{\partial v_j}{\partial \omega_{ij}} = x_{out,i}$ يمثل الخرج الفعلي من الطبقة السابقة، أما الحد الآخر في المعادلة (5-4):

$$\frac{\partial E_q}{\partial v_j} = -(d_{qj} - x_{out,i})g(v_j) \cong -\delta_j \quad (5 - 4)$$

يمثل $g(v)$ المشتق الأول لتابع التفعيل (غير الخطي) فنحصل على المعادلة (6-4):

$$\Delta\omega_{ij} = \mu \delta_j x_{out,i} \quad (6 - 4)$$

ومنه يمكن كتابة معادلتى تعديل الأوزان والانزياحات كما يلي (7-4) و (8-4):

$$\omega_{ij}(k+1) = \omega_{ij}(k) + 2\mu \delta_j x_{out,i} \quad (7 - 4)$$

$$b_{ji}(k+1) = b_{ji}(k) + 2\mu \delta_j \quad (8 - 4)$$

يمثل الحد μ في المعادلتين (7-4) و (8-4) قيمة ثابتة هي معدل التعلم الذي هو قيمة محصورة بين 0 و 1 وكلما كانت هذه القيمة كبيرة كلما زادت سرعة التعلم ولكن يمكن أن تزداد قيمة الأخطاء ويمكن أن تؤدي لعدم استقرارية في التدريب والعكس بالعكس. يمثل الحد $\omega_{ij}(k+1)$ في المعادلة (7-4) قيمة

الوزن الجديدة بعد التحديث أما الحد $w_{ij}(k)$ يمثل القيمة السابقة القديمة قبل التحديث, في المعادلة (8-4) يمثل الحد $b_{ji}(k+1)$ قيمة الانزياح للعصبون الجديدة والحد $b_{ji}(k)$ يمثل قيمة الانزياح القديمة [10].

خطوات تطبيق خوارزمية الانتشار الخلفي Back-propagation:

1. إسناد قيم بدائية صغيرة لأوزان عصبونات الشبكة.
2. حساب استجابة الشبكة لكل عينة في مجموعة التدريب المكونة من ثنائيات (دخل-خرج).
3. مقارنة الاستجابة المطلوبة (الهدف) مع الاستجابة الفعلية للشبكة وحساب كل الأخطاء المحلية من المعادلة (10-4).
4. تحديث أوزان وانزياحات الشبكة اعتماداً على المعادلتين (7-4) و (8-4).
5. تكرار الخطوات من 2 إلى 4 حتى تبلغ الشبكة درجة دقة تتسجم مع استجابة كافية لكل أمثلة التدريب.

مما سبق ذكره هنالك العديد من الخوارزميات المستخدمة في تدريب الشبكة العصبونية متعددة الطبقات MLP بطريقة الانتشار الخلفي Back-propagation لحساب الأخطاء. ولكن معظمها يعتمد على نفس مبدأ القاعدة دلتا المذكورة مسبقاً في المعادلات (3-4) و (7-4) و (8-4) وتختلف ببعض التحسينات التي يمكن أن تتغلب على مشاكل عملية أثناء التطبيق. من الصعب إيجاد قواعد ثابتة لتحديد أي منها هو الأسرع والأدق في التدريب بالنسبة لأي مشكلة مطروحة لأن ذلك يعتمد على عوامل عديدة [11] نذكر منها:

- 1- مدى تعقيد المشكلة المطروحة.
- 2- عدد عينات التدريب وأبعاد العينة.
- 3- عدد الأوزان والانزياحات التي يتم حسابها في الشبكة مع قيمة الخطأ المطلوب تحقيقه.
- 4- كون الشبكة العصبونية تستخدم من أجل التعرف على الأنماط Pattern Recognition أو تقريب تابع Function Approximation.

غالباً ما تعتمد هذه الخوارزميات على تقنيات متطورة لحماية الشبكة العصبونية مثل التوقف المبكر Early Stopping (ES) خلال عملية التدريب من الوقوع في مشاكل مثل زيادة التدريب Over-fitting التي تنقص من كفاءة عمل الشبكة خلال الفحص مثل انخفاض التعميم. من أشهر هذه الخوارزميات [11] نذكر في الجدول (1-4):

الجدول (1-4) بعض أشهر الخوارزميات المستخدمة في تدريب الشبكات MLP, مأخوذ عن [11].

#	اسم خوارزمية Back-propagation	مميزات الخوارزمية
1	Levenberg Marquardt (LM)	سريعة التقارب وتتطلب ذاكرة تخزين قليلة تستخدم خوارزمية تقريب لتلافي التعقيد في الحسابات
2	Bayesian Regularization (BR)	أبطأ من LM ولكنها تتناسب بشكل أفضل مع عينات التدريب القليلة
3	Scaled Conjugate Gradient (SCG)	يستخدم خوارزميات أمثلة عددية Optimization يمكن أن توفر وقت أكثر من خوارزمية Gradient Descent
4	Resilient Back-propagation (RB)	تم التغلب على مشاكل استخدام توابع Sigmoid, حيث يتم تعديل الأوزان بناءً على اتجاه المشتق وليس المطال كما في المعادلة (3-4)
5	Gradient Descent with Momentum and Adaptive learning rate rule (GDM)	تم التغلب على مشاكل النهايات المحلية Local Minimum بإضافة بارامتر آخر مع معدل التعلم لقاعدة دلتا المعادلة (3-4) وبالتالي إحراز كفاءة في التدريب والنتائج
6	Polak-Ribiere Conjugate Gradient (CGP)	كما في قاعدة دلتا الأساسية المعادلة (3-4) ولكن تحديد اتجاه البحث يتم وفق علاقة Polak-Ribiere
7	One Step Secant (OOS)	تم استخدام قاعدة دلتا المعادلة (3-4) مع quasi-Newton
8	Fletcher-Powell Conjugate Gradient (CGF)	كما في قاعدة دلتا الأساسية المعادلة (3-4) ولكن تحديد اتجاه البحث يتم وفق علاقة Fletcher-Powell
9	Powell-Beale Conjugate Gradient (CGB)	كما في قاعدة دلتا الأساسية المعادلة (3-4) ولكن تحديد اتجاه البحث يتم وفق علاقة Powell-Beale

10	Gradient Descent with Adaptive Learning Rule (GDA)	فيها يتم تعديل الأوزان ليس فقط من اتجاه ومطال المشتق بل بمعدل تعلم متغير
11	Gradient Descent (GD)	قاعدة دلنا الأساسية المعادلة (3-4) دون تحسينات
12	Sequential Order Incremental Training with Learning Functions	يتم تعديل الأوزان كل مرة عند كل إدخال عينة للشبكة وليس بعد كل عصر Epoch كالمعتاد

4-3-1- أنواع الشبكات العصبونية: سوف نذكر بشكل مختصر أنواع الشبكات حسب أسلوب التعلم بإضافة لذكر ميزات ومساوئ استخدام الشبكات العصبونية بشكل عام [9, 10]:

(1) التعليم الموجه Supervised Learning:

1. الشبكات العصبونية ذات التغذية الأمامية (Feed-Forward Network (FFN):
غالباً ما تتكون من عصبونات متعددة الطبقات MLP كل عصبون هو وحدة قائمة بحد ذاته وهو مكون من مداخل وتابع تحويل ومخرج، تتصل عصبونات الطبقات (دخل - مخفي - خرج) ببعضها أي كل عصبون في طبقة ما يتصل مع عصبون في طبقة أخرى ولكن ليس في نفس الطبقة الواحدة، يتم تحديد الأوزان الواصلة بين الطبقات بأساليب عدة منها طريقة الانتشار الخلفي Back-Propagation.
2. الشبكات العصبونية ذات التغذية الخلفية (Feed-Back Network FBN): تقريباً تشابه الشبكات FFN ولكن يمكن أن تتصل عصبونات الطبقة الواحدة مع بعضها ومع الخرج لتأمين التغذية العودية الراجعة (من الخرج مثلاً).
3. الشبكات العودية (التكرارية) (Recurrent Networks):
1) شبكة Elman الجزئية العودية: هي مزيج من نوعين من الشبكات العصبونية مثل FFN مع عودية جزئية ذات تغذية راجعة FBN وهي تستفيد من مزايا كلا الشبكتين وتقلل من المساوئ.
- 2) الشبكات الكاملة العودية (Hopfield Network): تعد هذه الشبكات على قواعد Hebb التي تعتمد طريقة ربط خاصة مثل "ربط العصبونات التي تستجيب مع بعضها Fire together, wire together".


(2) التعليم غير الموجه Unsupervised Learning:

1. الشبكات العصبونية ذات التعليم الذاتي (SOM) Self-Organized Map:

- شبكات كوهنن Kohonen Maps.
- التكميم الشعاعي (LVQ) Learning Vector Quantization.
- شبكات تابع القاعدة الشعاعي Radial Basis Function Networks: يستخدم هذا النوع من نمط التعليم غير الموجه عندما تكون قاعدة التصنيف غير معروفة ويمكن في حال اختيار قاعدة التصنيف يدوياً اعتباره من النوع الموجه.

4-3-5 الوحدة الأساسية في تكوين الشبكات العصبونية

يعتبر العصبون هو الوحدة الأساسية في تكوين الشبكة العصبونية ولتسهيل الدراسة والبحث العلمي تم تمثيل هذه الوحدة بنموذج رياضي يحاكي عمل العصبون في دماغ الإنسان. حيث كل عصبون بحد ذاته هو وحدة حسابية خطية يستخدم لحل المسائل الخطية على الأغلب ولكن استخدام أكثر من عصبون مترابطة مع بعضها يساعد في زيادة قدرة هذه العصبونات على حل المسائل المعقدة وغير الخطية - كما في بحثنا هذا- حيث أن الكم الكبير من البارامترات المطروحة في المسألة والمتغيرة بشكل خطي يجعل من الصعب الحصول على معادلة واضحة - مهما كان نوعها تفاضلية أو تكاملية إلخ...- تربط بين معطيات المسألة ومخرجاتها. من هنا أتى دور الشبكات العصبونية متعددة الطبقات والعصبونات التي تعتبر مثل الصندوق الأسود والوحدة الأساسية في تركيبه هي العصبون [10], الذي يتكون من أربعة مكونات أساسية مبينة في الشكل (4-2) هي:



- 1- المشابك أو وصلات الاتصال التي توفر الأوزان ω_j لقيم الدخل x_j من أجل $j=1, \dots, m$.
- 2- آلية جمع Adder/summation function لقيم المداخل الموزونة لحساب قيمة الدخل لتابع التفعيل حسب المعادلة (9-4) التالية:

$$v = \sum_{j=1}^m \omega_j x_j \quad (9-4)$$

حيث أن ω_0 يسمى الانزياح Bias وهو قيمة عددية متعلقة بالعصبون، وبالتالي من أجل $x_0 = 1$ تصبح المعادلة (9-4) بالشكل التالي:

$$v = \omega_0 + \sum_{j=1}^m \omega_j x_j \quad (9-4)$$



- 3- تابع تفعيل (أو تابع نقل) Activation/Transfer Function الذي يرسم قيمة الخرج للعصبون كما هو موضح في الشكل (1-4): ويمكن أن يكون تابع خطي Pure Line أو تابع لوغاريتمي Logarithmic أو تابع ظل Tangent , يعرض الجدول (2-4) بعض أشكال توابع التفعيل التي





يمكن أن تستخدم في الشبكات العصبونية وذلك تبعاً لبنية الشبكة ومجالات بيانات الدخل وغيرها من العوامل المؤثرة. من أشهر التوابع المستخدمة في هذا المجال هو Sigmoidal Function الذي تعرف معادلته حسب المعادلة (10-4) [11]:

$$f(x) = \frac{1}{1 + e^x} \quad (10 - 4)$$

4- المخارج: وهي قيم واضحة بالنسبة للمصمم قريبة من البيئة الواقعية أو ترميز متفق عليه تبعاً لمحاكاة المصمم وقيم الهدف المطلوبة.


الجدول (2-4) أنواع توابع التفعيل التي يمكن أن تستخدم حسب التطبيق ونمط بيانات الدخل، مأخوذ عن [11].

اسم التابع	وصف التابع	شكل التابع
Hard-Limit Function	تابع الخطوة الواحدية يأخذ قيمتين إما صفر أو واحد (يمكن أن يكون $1+$ أو $-$ 1 ثنائي القطبية) $a(n) = \begin{cases} +1, & n \geq 0 \\ 0, & n < 0 \end{cases}$ كما يمكن أن يكون تابع خطوة مع قيمة عتبة θ يتم مقارنتها.	 $a = \text{hardlim}(n)$
Linear Function	التابع الخطي $a(n) = n$ كما يمكن استخدام عتبة مقارنة θ لأخذ جزء من المنحني (العلوي أو السفلي)	 $a = \text{purelin}(n)$

 $a = \text{satlins}(n)$	كما ويدعى أحياناً بـ Piecewise liner function $a(n) = \begin{cases} +1 & \text{if } n \geq +1 \\ n & \text{if } -1 \leq n \leq +1 \\ -1 & \text{if } n \leq -1 \end{cases}$	Saturated Linear Function
 $a = \text{logsig}(n)$	$a(n) = \frac{1}{1+e^{-n}}$ وهو الأكثر استخداماً يأخذ هذا التابع قيم الدخل بين $\pm \infty$ ويعطي خرج بين صفر و 1 فقط ويمكن أن يكون له قيمة عتبة θ وفق $a(n) = \frac{1}{1+e^{-(n+\theta)}}$	Binary Sigmoid Function (logsig)
 $a = \text{tansig}(n)$	$a(n) = \tanh(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}} = \frac{1 - e^{-2n}}{1 + e^{-2n}}$ يأخذ هذا التابع قيم الدخل بين $\pm \infty$ ويعطي خرج بين 1- و 1+ فقط	Bipolar Sigmoid Function (Hyperbolic Tangent) (tansig)
 $a = \text{radbas}(n)$	$a(n) = e^{-n^2}$ تابع التوزع المنتظم (التابع الغاوسي) <i>Function Gaussian</i> يمكن لهذا التابع أن يأخذ أي قيمة عددية سالبة أو موجبة ويعطي وفق قيم موجبة محصورة بين [0,1].	Radial Basis Function (RBF)

عند اتصال العصبونات مع بعضها البعض تتشكل لدينا شبكة عصبونية بشكل طبقات تتناقل الإشارة بين بعضها وتختلف البيئة حسب تشبيك العصبونات فيمكن أن تكون مرتبة بطبقات ويمكن أن تكون متشابكة بشكل كلي أو جزئي. يوضح الشكل (3-4) شبكة عصبونية من نوع مستقبلات متعددة الطبقات Multi-

Layer Perceptron (MLP) تُعرف الطبقة النهائية التي تعطينا الخرج بطبقة الخرج Output Layer أما الطبقة الأولى التي تستقبل المدخلات فتُعرف بطبقة الدخل Input Layer. أما بقية الطبقات البينية فتُعرف بالطبقة المخفية Hidden Layer. وبشكل مشابه لما يحدث فيزيولوجياً في دماغ الانسان تستقبل عصبونات الدخل قيم الدخل وتقوم الشبكة بعمليات حسابية داخلية ينتج عنها قيم معينة تسبب تفعيل عصبونات الخرج لتنتقل النتيجة للوسط خارج العصبون.



تتصل العصبونات مع بعضها البعض على شكل طبقات (MLP) Multi-Layer Perceptron يختلف فيها عدد العصبونات في كل طبقة بحيث يكون لها دخل مشترك وخرج مشترك، الشبكة العصبونية MLP تتكون على الأقل من طبقة بينية (مخفية) على الأقل وعند تحديد عدد العصبونات في كل طبقة لابد من مراعاة الملاحظات التالية:

1- طبقة الدخل Input Layer : تحوي عدد عصبونات مساوي لأبعاد العينات المستخدمة (عدد أبعاد عينة بيانات الدخل).

2- طبقة الخرج Output Layer : تحوي عدد عصبونات مساوي لأبعاد الهدف أو للعدد الأمثل للبتات لتمثيل هذه المسألة بشكل بولياني أو بأي شكل آخر.

3- الطبقة المخفية Hidden Layer: تحوي عدد عصبونات غير محدد لكن يوجد عدد مناسب نحصل به على أفضل دقة عمل للشبكة العصبونية (نسبة الخطأ في الشبكة أصغرية).

تحديد عدد عصبونات الطبقة المخفية:

في هذه الدراسة اعتمدنا على بعض القوانين التجريبية التي وردت في بعض المراجع مثل [12], ففي حالة الشبكة العصبونية متعددة الطبقات MLP ذات الطبقة المخفية الوحيدة يمكن تطبيق المعادلة (11-4) لتحديد عدد عصبونات الطبقة المخفية:

$$2\sqrt{(m+2)N} \quad (11-4)$$

حيث أن m تدل على عدد مخارج الشبكة العصبونية (عدد عصبونات طبقة الخرج) وتدل N على عدد العينات المدخلة للشبكة أثناء عملية التدريب [12].

أما في حالة استخدام طبقتين مخفيتين في الشبكة العصبونية فيمكن الاعتماد على القانون التالي لحساب العدد التقريبي لعصبونات الطبقات المخفية كما في المعادلتين (12-4) و (13-4) [12]:

في الطبقة المخفية الأولى:

$$\sqrt{(m+2)N} + 2\sqrt{N/(m+2)} \quad (12-4)$$

في الطبقة المخفية الثانية:

$$m\sqrt{N/(m+2)} \quad (13-4)$$

من الملاحظات الجديرة بالذكر أن تحديد عدد العصبونات في هذه الطبقة يتعلق بعدة عوامل منها: عدد عصبونات الدخل والخرج - عدد عينات التدريب - تركيبة الشبكة - مدى تعقيد العلاقة بين الدخل والخرج - نوع توابع تفعيل العصبونات المخفية وغيرها. وهناك عدد معادلات مقترحة لحساب هذا العدد ولكن ليس هنالك معادلة دقيقة لتحديده بسبب كثرة العوامل المؤثرة، ومع ذلك يمكن استخدام المعادلات (11-4) و (12-4) و (13-4) لتحديده بشكل تقريبي ثم انتقاء عدد أكبر منه لتغطية مجال أكبر

للتجريب. بالنتيجة العدد الأمثل لعصبونات الطبقة المخفية في شبكة عصبونية معينة هو عدد وسطي يتحدد خلال عملية التدريب يحمي الشبكة من الوقوع في مشكلة التدريب الزائد Over-fitting من جهة وفي مشكلة التدريب غير الكافي Under-fitting من جهة أخرى. في التدريب الزائد Over-fitting يحدث انخفاض في قدرة الشبكة على اتخاذ القرار من أجل العينات الجديدة التي لم يسبق أن تدربت عليها وهذا ما يعرف بقدرة الشبكة على التعميم Generalization, أما في مشكلة التدريب غير الكافي Under-fitting يكون خطأ التدريب في الشبكة كبير وخطأ التعميم كبير لأن عدد العصبونات المخفية غير كافي حيث أن الشبكة غير قادرة على تمثيل التعقيد في الشبكة.

أساليب الإدخال للشبكة العصبونية:

هنالك نوعين لإدخال عينات التدريب للشبكة العصبونية تختلف حسب توقيت عملية تعديل الأوزان الذي يجري خلال عملية التدريب هي [11]:

1- التدريب المتزايد Incremental Training: يتم تعديل الأوزان والانزياحات فيه في كل مرة يتم فيها إدخال عينة تدريب للشبكة.

2- التدريب دفعة واحدة Batch Training: تعديل الأوزان والانزياحات يتم فقط بعد إدخال كامل عينات الدخل للشبكة, وهذا ما يعرف بـ عصر التدريب Epoch.

تعريف: عصر التدريب Epoch: هو إدخال كامل عينات التدريب للشبكة لمرة واحدة.

وبالتالي يمكن أن يتم تدريب الشبكة لأكثر من عصر وحسب نمط تحديث الأوزان في خوارزمية التدريب المستخدمة يتم تعديل الأوزان كل عصر أو بعد إدخال كل عينة.

متغيرات الخوارزمية Variables of Algorithm

لكل خوارزمية من الخوارزميات المذكورة في الجدول (4-1) مجموعة من المتغيرات التي تحدد عملها وخيارات التوقف وتعديل الأوزان وحساب الخطأ وأصغر خطأ مطلوب الوصول إليه وغالباً ما تحوي هذه المتغيرات قيم افتراضية [11]. مثلاً خوارزمية Levenberg Marquardt تتضمن:

- 1- عدد أمثلة الدخل حيث يتم تقسيم بيانات الدخل إلى ثلاثة مجموعات (60% تدريب - 20% توثيق - 20% فحص) وسيتم الحديث عنه لاحقاً بشكل موسع في الفقرة "مشكلة التدريب الزائد".
- 2- عدد عصور التدريب Epochs تكون بشكل افتراضي 1000.
- 3- معدل التعلم (LR) Learning Rate تكون بشكل افتراضي 0.001.
- 4- قيمة الخطأ الأصغرية المراد تحقيقها خلال التدريب Goal تكون بشكل افتراضي 0.
- 5- العدد الأعظمي لاختبار مجموعة التوثيق: بعد عدد معين من اختبار خطأ مجموعة التوثيق إذا كان في حالة زيادة وليس نقصان كما هو الحال في خطأ التدريب يتم إيقاف عملية التدريب للمحافظة على قدرة الشبكة على التعميم, افتراضياً يكون عدد هذه الاختبارات 6.
- 6- متغيرات تتعلق بمعدل التعلم وهي: خطوة الزيادة (10) وخطوة النقصان (0.1) وأكبر خطوة زيادة لمعدل التعلم يمكن أن يبلغ القيمة ($10e^{+10}$) بعدها تتوقف الخوارزمية, حيث تتحكم هذه المتغيرات بسلوك الخوارزمية في تسريع أو تبطيء التدريب.

تعريف: معدل التعلم Learning Rate: هو حجم الخطوة التي تستخدمها الخوارزمية (أو الشبكة) لتعديل الأوزان والانزياحات خلال عملية التدريب. تحديد معدل التعلم يجب أن يتم بعناية لتجنب الشبكة من الوقوع بمشاكل مثل عدم الاستقرار (سلوك اهتزازي Oscillating حول النهاية الصغرى التي نريد الوصول إليها) عندما تكون قيمة معدل التعلم كبير, وبالمقابل عندما تكون هذه القيمة صغيرة جداً يمكن أن تسبب زيادة الزمن اللازم للتدريب وبلوغ الهدف (أصغر خطأ ممكن).

في الخوارزميات الأخرى مثل Bayesian Regularization و Resilient Back-propagation يمكن أن نجد نفس المتغيرات أيضاً المذكورة في LM, ولكن في خوارزمية Scaled Conjugate Gradient يمكن أن نجد نفس المتغيرات السابقة ما عدا البارامترات المتعلقة بمعدل التعلم. عوضاً عن ذلك نجد بارامترين هما: Sigma الذي يحدد خطوة التغيير في الأوزان بالنسبة للمشتق الثاني المعادلة (3-4) وبأخذ قيمة افتراضية $5.0e^{-5}$, المتغير الثاني هو Lambda الذي يأخذ قيمة افتراضية $5e^{-7}$ مهمته تعيين محددات مصفوفة Hessian. أما باقي الخوارزميات تقريباً تحتوي نفس المتغيرات المذكورة مسبقاً.

شرط توقف الخوارزمية: أي خوارزمية من الخوارزميات السابقة يمكن أن تتوقف عن عملية التدريب بعد تحقق أحد المعايير التالية:

- 1- تحقيق الخطأ المطلوب الوصول إليه GOAL.
- 2- انتهاء عصور التدريب EPOCHS.
- 3- انتهاء الزمن الأعظمي المسموح به لحصول تقارب الخوارزمية TIME.
- 4- تحقق شرط التوقف المبكر Early Stopping بحيث يتجاوز العدد الأعظمي لاختبار مجموعة التوثيق.

4-3-1-6 مشكلة التدريب الزائد Over-fitting وكيفية حلها

يمكن خلال عملية التدريب أن تعاني الشبكة من مشكلة التدريب الزائد الذي يدفع الشبكة إلى أن تسلك سلوك الذكرة حيث تعطي كفاءة عالية من أجل العينات التي تم التدريب عليها ولكن تبدي كفاءة منخفضة من أجل العينات التي لم يسبق أن تدربت عليها وهنا نقول أن الشبكة فقدت قدرتها على التعميم. لحل هذه المشكلة هنالك عدة طرق تم استخدامها لكشف هذه الحادثة خلال عملية التدريب وبالتالي إيقاف التدريب والمحافظة على كفاءة حتى من أجل العينات التي لم يسبق أن تدربت عليها من قبل، نذكر منها:

➤ اختبار مجموعة توثيق وفحص خلال التدريب والتي تعرف بـ Split-sample (hold-out

Validation): تعتمد هذه الطريقة - والمتبعة في بحثنا هذا - على تقسيم العينات الكلية التي يتم استخدامها عادة بشكل كامل في التدريب إلى ثلاثة مجموعات:

1- مجموعة التدريب Training Set: تتم عملية التدريب على العينات المتوفرة والتي تشمل القسم الأكبر (60% مثلاً) ويكون الهدف هو الوصول لأقل قيمة للخطأ MSE (انحراف قيم الخرج عن قيم الهدف).

2- مجموعة التوثيق Validation Set: تلي عملية التدريب عملية توثيق يتم تحديد أداء الشبكة العصبونية على نماذج جديدة (20% مثلاً) التي لم يتم التدريب عليها مسبقاً خلال عملية التدريب، وفيها يتحدد معيار توقف التدريب عندما تزداد قيمة الخطأ عن قيمة معينة خلال عدد أدوار تدريب معينة مسبقاً.

3- مجموعة الفحص Testing Set: بعد انتهاء التدريب والتوثيق يتم فحص كفاءة التصنيف للشبكة العصبونية بشكل كلي بمجموعة الفحص (20% مثلاً).

طريقة التوقف المبكر Early Stopping للحفاظ على قدرة الشبكة على التعميم: تتضمن هذه الطريقة الانتباه للنقاط التالية خلال إنجاز عملية التدريب للشبكة العصبونية:

- (1) تقسيم العينات المتاحة للتدريب إلى مجموعتين: مجموعة تدريب Training Set ومجموعة توثيق Validation Set.
- (2) استخدام أكبر عدد مناسب لعصبونات الطبقة المخفية.
- (3) استخدام قيم ابتدائية عشوائية صغيرة للأوزان Weights والانزياحات Biases.
- (4) استخدام معدل تعلم بطيء (قيمة صغيرة).
- (5) حساب معدل خطأ التوثيق بشكل دوري مستمر خلال التدريب.
- (6) إيقاف عملية التدريب عند بدء تزايد معدل خطأ لعينات مجموعة التوثيق.

التعميم Generalization: من أهم ميزات الشبكات العصبونية هي قدرتها على التعميم أي إمكانية الشبكة على التصنيف بشكل دقيق حتى من أجل البيانات المدخلة التي لم يتم التدريب عليها. يتم ذلك بشكل عملي من خلال طريقة التوقف المبكر التي تم ذكرها في الفقرات السابقة والتي يمكن أن نختصرها بتقسيم عينات الدخول إلى مجموعتين أساسيتين هما مجموعة التدريب Training Set ومجموعة فحص Testing Set. يتم استخدام مجموعة التدريب من أجل تعليم الشبكة وتعديل الأوزان أما مجموعة الفحص فيتم من خلالها تقييم كفاءة الشبكة في التعلم أي يتم حساب استجابة الشبكة التي قد تدربت وتم تثبيت أوزانها بإدخال عينات الفحص لها -التي لم يتم التدريب عليها من قبل - ثم تقييم نتائج الخرج.

من الملاحظات المهمة التي يجب الانتباه إليها عند استخدام الطريقة السابقة أن تقدير خطأ التعميم يكون أكثر دقة ومصادقية عند استخدام مجموعة اختبار منفصلة تماماً عن مجموعتي التدريب والتوثيق، وأن لا يتم ذلك خلال عملية التدريب ولكن بعد الانتهاء منها وتثبيت الأوزان ثم محاكاة الشبكة بشكل مستقل.

من ميزات استخدام هذه الطريقة: سرعة التطبيق بالنسبة للطرق الأخرى، ويمكن أن تستخدم بشكل ناجح بالنسبة للشبكات التي يتجاوز فيها عدد أوزان الشبكة بكثير حجم عينات التدريب، وكل ما تتطلبه هذه الطريقة يتركز فقط بأن يحدد المستخدم ما يناسبه من معايير الإيقاف عملية التدريب.

4-1-3-7 بعض التطبيقات الطبية للشبكات العصبونية

دخلت التقنيات الذكية للشبكات العصبونية بشكل واسع في مختلف مجالات الحياة وأضحت أسلوب معياري لنمذجة الذكاء البشري مما ساهم في إحداث تطورات عدة أهمها في مجال التشخيص الطبي:

- 1- التشخيص السريري Clinical Diagnosis.
 - نظام للمساعدة في تشخيص أمراض القلب.
 - نظام للمساعدة في تشخيص أمراض الجهاز التنفسي.
- 2- تفسير وتحليل الصور الطبية Image Analysis and Interpretation.
 - الكشف الآلي للأورام السرطانية.
 - التحديد الآلي لمنطقة العلاج الشعاعية.
- 3- تفسير وتحليل الإشارة الطبية Signal Analysis and Interpretation.
 - إشارة القلب الكهربائية ECG.
 - إشارة الدماغ EEG.
- 4- تطوير الأدوية Drug Development.

4-2 طرق تقييم دقة تصنيف أنظمة التشخيص الطبي

قبل البدء بذكر المعايير لابد من التطرق لبعض المصطلحات المساعدة التي تعتمد بالدرجة الأولى على قرار الطبيب (القرار المرجعي) حيث عند تطابق قرار نظام التشخيص مع قرار الطبيب يعتبر القرار صحيح ويأخذ القيمة True بينما عندما يتعارض يعتبر القرار غير صحيح ويأخذ القيمة False، مع اعتبار أن وجود المرض عند شخص هو حالة Positive وعدم وجوده هو حالة Negative وهي [14]:

(1) **True Positive (TP)**: تم اثبات أن الحالة المدروسة حسب رأي الطبيب هي حالة مرضية ونتيجة تشخيص (تصنيف) الشبكة العصبونية كذلك وجود حالة مرضية.

(2) **True Negative (TN)**: تم اثبات أن الحالة المدروسة حسب رأي الطبيب هي حالة سليمة وكانت نتيجة تشخيص (تصنيف) الشبكة العصبونية كذلك عدم وجود حالة مرضية.

(3) **False Positive (FP)**: إذا كانت نتيجة تشخيص (تصنيف) الشبكة العصبونية هي وجود مرض في حالة مدروسة ولكن فعلياً حسب رأي الطبيب الحالة المدروسة هي حالة سليمة (عدم وجود مرض).

(4) **False Negative (FN)**: إذا كانت نتيجة تشخيص (تصنيف) الشبكة العصبونية هي عدم وجود مرض في حالة مدروسة ولكن فعلياً حسب رأي الطبيب الحالة المدروسة هي حالة مرضية (وجود مرض).

مما سبق عرضه نجد أن كل من True Positive و True Negative يعبر عن حالات حقيقية صحيحة بين نتيجة التشخيص (تصنيف الشبكة العصبونية) والواقع الحقيقي المثبت (رأي الطبيب)، لذلك تعرف بـ Standard of Truth. أما الحالتين الباقيتين FP و FN تعبر عن حالات معاكسة للواقع الحقيقي المثبت من قبل الطبيب.

المعايير المستخدمة في تقييم نتائج التصنيف هي [14]:

1- **دقة التصنيف Accuracy Classification**: تعبر عن معدل عدد الحالات المصنفة بشكل

صحيح والتي هي مجموع TP و TN بالنسبة لعدد الحالات الكلية $n = TP + TN + FP + FN$ ويعبر عنها بالمعادلة (4-14):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (14 - 4)$$

2- **حساسية التصنيف Sensitivity Classification**: تعبر عن معدل عدد الحالات الإيجابية

المصنفة بشكل صحيح والتي هي TP بالنسبة لعدد الحالات الإيجابية الحقيقية والسلبية الخاطئة

والتي هي $TP + FN$ وتعرف هذه القيمة أيضاً بمعدل الحالات الموجبة الصحيحة True Positive Rate (TPR) كما في المعادلة (4-15):

$$Sensitivity = \frac{TP}{TP + FN} \quad (15 - 4)$$

3- **نوعية التصنيف Specificity Classification**: تعبر عن عدد الحالات السلبية المصنفة بشكل

صحيح والتي هي TN بالنسبة لعدد الحالات السلبية الحقيقية والإيجابية الخاطئة والتي هي $TN + FP$ ومنه يتم استنتاج معدل الحالات الموجبة الخاطئة $False Positive Rate (FPR) = 1 -$ Specificity كما في المعادلة (4-16):

$$Specificity = \frac{TN}{TN + FP} \quad (16 - 4)$$

4- **القيمة التنبؤية الموجبة Positive Predicted Value (PPV)**: تعبر عن معدل الحالات

المرضية التي تم كشفها بشكل صحيح بالنسبة للحالات المرضية غير الصحيحة كما هو موضح في المعادلة (4-17):

$$PPV = \frac{TP}{TP + FP} \quad (17 - 4)$$

5- **القيمة التنبؤية السالبة Negative Predicted Value (NPV)**: تعبر عن معدل الحالات السليمة

التي تم كشفها بشكل صحيح بالنسبة للحالات السليمة غير الصحيحة كما هو موضح في المعادلة (4-18):

$$NPV = \frac{TN}{TN + FN} \quad (18 - 4)$$

6- **متوسط مربع الأخطاء Mean Squared Error (MSE)**: يعبر عن مجموع مربعات كافة


الأخطاء الحاصلة أثناء عملية التدريب كافة العينات المستخدمة بشكل وسطي، الخطأ المحسوب لكل عينة هو مقدار انحراف خرج هذه العينة عن قيمة الهدف بعد تثبيت الاوزان والانزياحات في الشبكة المدربة. وطبعاً كل ما كان هذا الخطأ أصغر كلما عبر عن دقة في تصنيف الشبكة العصبونية وقدرة الشبكة على التعلم. ويعبر عنه بالمعادلة (4-19) و (4-20) [11]:

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{NP} \quad (19 - 4)$$

$$MSE = \frac{SSE}{N} \quad (20 - 4)$$

حيث أن P يمثل عدد العصبونات في الخرج و N عدد عينات التدريب المستخدمة في الشبكة و y_{ij} هو خرج الشبكة من أجل العينة i عند عصبون الخرج z و d_{ij} هو قيمة الهدف المطلوبة من أجل العينة i عند عصبون الخرج z . ويمثل SSE مجموع مربعات الأخطاء Sum Squared Error.

7- **منحني Receiver Operating Characteristic (ROC)**: هو رسم لمنحني يكون فيه المحور الشاقولي هو محور معدل الحالات الموجبة الصحيحة TPR (الحساسية) والمحور الأفقي هو محور معدل الحالات الموجبة الخاطئة FPR (1- النوعية) حسب الشكل (4-4).



يحدد تقاطع نقطة من TPR مع نقطة من FPR نقطة واحدة في مستوى المحدد بالمحورين وبالتالي أي زيادة للحساسية ترافقها زيادة في النوعية، موضع النقطة على المستوى يحدد جودة التصنيف. يتوضع المنحني المثالي في الشكل (4-4) بحيث يمر في النقطة ذات الإحداثيات (1,0) ويكون المنحني قائم في تلك النقطة وعندها تكون الحساسية 100% والنوعية 100% ويكون التصنيف عندها مثالي Perfect Classification. الخط القطري الذي يمر بالنقطة (0,0) يفصل بين التصنيف الجيد في القسم العلوي والتصنيف الرديء في القسم السفلي.

نتائج من منحني ROC:

- ✓ كلما كانت نقاط منحني ROC أقرب للمنحني المثالي كلما كان التصنيف أكثر دقة، وبالمقابل كلما كانت نقاط منحني ROC أقرب للخط القطري كلما كان التصنيف أقل دقة.
- ✓ كلما كان اقتراب نقاط المنحني من النقطة المثالية (1,0) أسرع كلما كانت ذلك مفيداً للنتائج المستحصلة.
- ✓ مساحة السطح الواقع تحت منحي ROC مفيد جداً في تحديد دقة التصنيف للشبكة العصبونية.

8- مساحة السطح تحت منحني ROC والمعروفة بـ (Area Under ROC (AUC: نلاحظ من الشكل (4-4) أن مساحة السطح المحصور تحت المنحني يمكن أن تزودنا بمعلومات مهمة عن دقة التصنيف بحيث أنه مع الاقتراب من الزاوية اليسارية العلوية تزداد معه قيم الحساسية والنوعية وبالتالي دقة التصنيف. مع زيادة هذه المساحة تزداد الدقة والعكس بالعكس. تعرف المساحة هذه بـ AUC وتحسب حسب المعادلة (4-21) [14]:

$$AUC = \int_0^1 ROC(t)dt \quad (21 - 4)$$

حيث أن $t = (1 - \text{specificity})$ والتابع $ROC(t)$ هو الحساسية ويتم حساب التكامل على المجال [0,1].

وبالتالي النتيجة التي نحصل عليها من حساب هذه القيمة يمكن تقييم دقة التصنيف للشبكة العصبونية المقترحة حسب الجدول (4-3):

الجدول (3-4) تقييم جودة تصنيف نظام التشخيص حسب قيم المساحة المحصورة تحت منحنى ROC, مأخوذ عن [14].

AUC Range	Classification
$0.9 < AUC < 1.0$	Excellent
$0.8 < AUC < 0.9$	Good
$0.7 < AUC < 0.8$	Worthless
$0.6 < AUC < 0.7$	Not good

9- خطأ التعميم **Generalization Error**: تقييم كفاءة الشبكة يتم من خلال حساب متوسط مربع الأخطاء MSE حسب المعادلة (4-19) وبالتالي تكون قدرة الشبكة على التعميم عالية كلما كان هذا الخطأ أصغرياً. عملياً تكون تعميم الشبكة عالي كلما كان خطأ مجموعة الفحص يقترب من خطأ مجموعة التدريب.

3-4 بيئة عمل الماتلاب MATLAB الخاص بالشبكات العصبونية

بيئة العمل المستخدمة في تدريب الشبكة العصبونية التي تم العمل عليها في هذا البحث هي الماتلاب مع صندوق الأدوات المتخصص بالشبكات العصبونية الصناعية MATLAB (R2012a) Neural Network Toolbox. تم تشغيل هذا البرنامج على جهاز حاسب بالمواصفات التالية:

نوع المعالج	سرعة المعالج	الذاكرة المؤقتة	نظام التشغيل	ذاكرة الإظهار	دقة العرض
Intel® Core™2 Duo, 2 Cores	CPU 2.00GHz	RAM 3.0GB	Windows 7	384 MB	1366 × 768 × 60 hertz

4-4 تحويل فورييه (FT) Fourier Transformer

يوفر تحويل فورييه طريقة بديلة لتمثيل البيانات فبدلاً من تمثيل البيانات وفق علاقة تربط بين الزمن ومطال إشارة ما، يتم تمثيل هذه الإشارة بكمية المعلومات المحتواة عند ترددات مختلفة. إذا تحويل فورييه ينقل الإشارة من الفضاء الزمني Time Domain إلى فضاء ترددي Frequency Domain وبالمقابل يوجد تحويل الإشارة لاسترجاع الإشارة من الفضاء الترددي إلى الزمني ويسمى تحويل فورييه العكسي. أي

$$F(f) = \int_{-\infty}^{+\infty} f(x)e^{-i2\pi xf} dx$$

(22-4) المعادلة

$$f(x) = \int_{-\infty}^{+\infty} F(f)e^{i2\pi xf} df$$

(23-4) المعادلة

حيث أن $i = \sqrt{-1}$ و f هو تردد الإشارة ويكون نبض الإشارة $\omega = 2\pi f$.

$$F(\omega) = \sum_{k=0}^{n-1} f(kT)e^{-i\omega kT} \quad (24-4)$$

4-5 دراسة علاقة الترابط الخطي بين متحولين عشوائيين Linear Correlation

~ 75 ~

$$r_{X,Y} = \frac{cov(X,Y)}{\sigma_X \sigma_Y} = \frac{E((X - \mu_X)(Y - \mu_Y))}{\sigma_X \sigma_Y} \quad (25 - 4)$$

وبما أن التوقع الرياضي $E(X) = \mu_X$ و $E(X^2) = \sigma_X^2 + E^2(X)$ عندها يمكن كتابة المعادلة (25-4) وفق المعادلة (26-4):

$$r_{X,Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)}\sqrt{E(Y^2) - E^2(Y)}} \quad (26 - 4)$$

من المعادلة السابقة يمكن أن نتوقع مجالات قيم الترابط التي يمكن أن تنتج لتقرير درجة ترابط المتحولين:

- 1- قيمة الترابط قريبة من 1 تدل على وجود علاقة ترابط خطية موجبة (تناسب) بين المتحولين.
- 2- قيمة الترابط قريبة من -1 تدل على وجود علاقة ترابط خطية سالبة (تناسب عكسي) بين المتحولين.
- 3- قيمة الترابط قريبة من 0 تدل على عدم وجود علاقة ترابط خطي بين المتحولين.

تعريف: التغاير Covariance: هو مقياس لكمية تغيير متحولين X و Y مع بعضهما (التفاوت هو حالة خاصة من التغاير عندما يكون المتحولات متساويان $X=Y$ أي $Cov(X,X)=Var(X)$). تكون قيمة التغاير موجبة عندما يتغير متحولان مع بعضهما البعض (إذا كان أحد المتحولين فوق قيمته المتوقعة، فإن الآخر أيضاً يكون فوق قيمته المتوقعة)، وعلى العكس فتكون قيمة التغاير سالبة عندما يكون أحد المتحولين فوق قيمته المتوقعة بينما الآخر يكون دونها.

إذا كان لدينا متحولين عشوائيين X و Y حيث لكل منهما القيمة المتوقعة $E(X) = \mu$ و $E(Y) = v$ بالتالي يمكن حساب التغاير وفق المعادلة (27-4):

$$Cov(X,Y) = E((X - \mu)(Y - v)) \quad (27 - 4)$$

كما يمكن كتابة المعادلة (27-4) وفق الشكل النهائي التالي باعتبار E هي تابع القيمة المتوقعة وفق المعادلة (28-4):

$$Cov(X,Y) = E(X.Y) - \mu v \quad (28 - 4)$$

ويمكن أن نعرف المتحولات العشوائية التي يكون لها تغير يساوي الصفر بالمتحولات غير المترابطة، ومنه إذا كان المتحولان X و Y **مستقلان** فإن التغير لهما يساوي الصفر وبالتالي بسبب استقلالهما نجد:

$$E(X.Y) = E(X).E(Y) = \mu v$$

وبالتعويض بالمعادلة (4-28) نحصل على: $Cov(X,Y) = \mu v - \mu v = 0$ ولكن يجب الانتباه إلى أن عكس العبارة السابقة ليس من الضروري أن يكون صحيح دائماً. حيث يوجد الكثير من أزواج المتحولات يكون بينها قيمة التغير صفر إلا أنها ليست مستقلة.

تعريف التفاوت Variance والانحراف المعياري Standard Deviation: يعد الانحراف المعياري الأكثر استخداماً من بين مقاييس التشتت الاحصائي لقياس مدى التبعثر الإحصائي وبمعنى آخر يدل على مدى امتداد مجالات القيم ضمن مجموعة البيانات الإحصائية. بينما التفاوت هو معدل مربعات انحرافات العلامات في التوزيع عن الوسط الحسابي.

يتأثر كل من التفاوت والانحراف المعياري بالقيم المتطرفة كما أنهما يرتبطان بالوسط الحسابي للتوزيع، أي أن التشتت الذي نعبر عنه بالتفاوت أو الانحراف المعياري ينسب إلى الوسط الحسابي وليس لأي نقطة أخرى في التوزيع. ويمكن حساب الانحراف المعياري للمتحولات $x_1, \dots, x_N$ بالمعادلة (4-29):

$$\sigma = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N (x_i^2 - Nm^2) \right)} \quad (29 - 4)$$

حيث أن N هو عدد المتحولات و m هو المتوسط الحسابي.

الخلاصة:

تعرضنا في هذا الفصل إلى دراسة أساليب التشخيص الآلي التي يمكن أن تستخدم في المجال الطبي والتي منها الأنظمة الخبيرة والشبكات العصبونية. شرحنا أيضاً الوحدة الأساسية في تكوين الشبكات

العصبونية والنموذج الرياضي للعصبون وكيفية تركيب الشبكة العصبونية متعددة الطبقات MLP من حيث بناء الشبكة وتحديد معاملاتها الرئيسة مثل عدد الطبقات وعدد العصبونات في كل طبقة ومعدل التعلم وخوارزمية التدريب التي تمكن الشبكة من التعلم والتعميم بالإضافة للاستفادة من تقنية التوقف المبكر. تحدثنا أيضاً بشكل مفصل عن المعايير الإحصائية المستخدمة في تقييم نتائج تصنيف الشبكات العصبونية مثل الدقة والحساسية والنوعية ومنحنيات ROC وقيم الخطأ MSE. عرضنا في النهاية كيفية دراسة الترابط الخطي للمتحولات وتحويل فورييه بالإضافة إلى تحديد بيئة العمل للتجارب. سنتطرق في الفصل التالي إلى التجارب العملية وكيفية تقسيم بيانات الدخل للشبكة وتحديد معاملات الشبكة العصبونية بحيث نحصل على النتائج الأولية ثم تقييمها وتعليلها بالإضافة إلى تقييم أداء التشخيص الآلي لبرنامج الجهاز ومقارنة النتائج من الفصل السادس.

الفصل الخامس


التجارب العملية

5-1 مقدمة:

تعرفنا في الفصل الثالث على المبادئ الأساسية المتبعة في تقييم وظيفة الرئة التنفسية بالإستعانة باختبارات وظيفة الرئة التي تم إجراؤها بجهاز وظائف الرئة المعياري PFT أو مقياس التنفس Spirometer والعلاقة التي ترتبط بها القياسات المأخوذة من هذا الجهاز مع الأصناف الأساسية لأمراض الرئة. تعرفنا أيضاً في الفصل الرابع على أساسيات وأنواع وأساليب الذكاء الصناعي والشبكات العصبونية المستخدمة في هذه الدراسة وخوارزميات التدريب وطرق تقييم النتائج وفق معايير إحصائية عديدة.

نعرض في هذا الفصل الجانب التطبيقي الذي من خلاله نشرح طرق استخدام المواد الأولية التي تحدثنا عنها مسبقاً من خلال التعرف على أساليب تحصيل البيانات ومعالجتها وتحليلها، ثم تقسيمها إلى مجموعات لمقارنة نتائجها. سنعرض بالإضافة إلى ذلك بالتفصيل مراحل بناء الشبكة العصبونية المستخدمة مع كل مجموعة من المجموعات من حيث عدد الطبقات وعدد العصبونات في كل طبقة للشبكة العصبونية متعددة الطبقات نوع MLP. قمنا في النهاية بتقييم النتائج وفق معايير تقييم الأداء التي تم التحدث عنها في الفصل السابق ومقارنتها وسرد بعض الأمثلة لأفضل الحالات المستحصلة.

يوضح الشكل (5-1) عرض الشبكة العصبونية المصممة بشكل مبسط لتوضيح المراحل التي سيتم خلالها بناء نموذج الشبكة العصبونية المطلوب الذي يحقق هدف تصنيف بيانات الدخل في طبقة الدخل (قياسات جهاز اختبار وظائف الرئة)، مروراً بالطبقة المخفية ذات توابع التفعيل غير الخطية وانتهاءً إلى طبقة الخرج (أصناف أمراض الرئة مع الحالة الطبيعية). أثناء عملية التدريب يتم تعديل أوزان الروابط بين هذه الطبقات بحيث تتمكن الشبكة من إيجاد العلاقة الرابطة بين الدخل والخرج لتصبح قادرة على تصنيفها بدقة تشخيصية مقبولة ومعتمدة من قبل أطباء اختصاصيين في هذا المجال. تسبق عملية إدخال العينات اللازمة للتدريب عمليات معالجة وتحليل حتى تتناسب مع بنية الشبكة، تليها عملية تحضير متغيرات بنية الشبكة للحصول على النتائج المطلوبة وفق الخوارزمية المبينة في الشكل (4-1) وفي النهاية الحصول على الخرج وتقييم النتائج وتحديد الدقة.



2-5 الحصول على عينات التدريب من جهاز PFT وتقسيم بيانات الدخل

تم الحصول على العينات اللازمة لتدريب الشبكة العصبونية الصناعية من اختبارات جهاز وظائف الرئة المتواجد في مشفى الأسد الجامعي - دمشق (جهاز تصنيع شركة إيطالية متخصصة بهذا النوع من الأجهزة COSMED) [7] ويعرف أحياناً بـ Pulmonary Function Test (PFT) أو جهاز قياس التنفس Spirometer: وهو أسلوب لتقييم وظيفة الرئة بقياس حجم الهواء الذي يمكن للمريض أن يفرغه من الرئتين بعد شهيق أعظمي. يوفر الجهاز آليات متقدمة لقياس حجوم وتدفقات الهواء الداخل والخارج للرئتين أثناء تنفس المريض وفق الاجراء المتفق عليه عالمياً ERS و ATS [6, 8].

البيانات التي تهمنا في هذا البحث يمكن أن نحصل عليها من إجراء اختبار Forced Vital Capacity الذي يوفر لنا معلومات هامة عن خصائص الرئة والمستخدمه بشكل شائع في المجال الطبي المتخصص بأمراض الجهاز التنفسي [6, 8] والتي يمكن أن تقسم إلى أربعة مجموعات حسب أهميتها في التشخيص كما هو معروض في الجدول (5-1) الذي يوضح مثال عن قيم القياسات لـ 24 مريض (عينة):

الجدول (1-5) القياسات الأساسية المستخدمة في تشخيص أمراض الرئة مقسمة إلى أربعة مجموعات وفق هذه الدراسة

المجموعة الرابعة															
المجموعة الثالثة: يارامترات إضافية															
المجموعة الأولى: يارامترات أساسية															
المجموعة الثانية: يارامترات المريض الفيزيولوجية															
#	Age	Gender	Height	Weight	Somke	FVC	FEV1	FEV1%	FEF25-75%	PEF	MEF75%	MEF50%	MEF25%	Flow	Volume
1	68	0	148	59	0	2.34	1.6	68.4	0.98	3.84	3.56	1.32	0.34	2186	7285
2	55	1	161	89	0	2.86	2.04	71.3	1.31	8.61	4.66	1.68	0.52	7974	6504
3	49	1	160	61	0	3.39	2.64	77.9	2.55	7.69	7.29	4.52	0.73	8209	11161
4	60	1	152	71	0	2.84	1.14	40.2	0.42	3.59	0.87	0.49	0.2	6923	14701
5	57	1	169	73	0	2.92	1.71	58.7	0.8	3.84	2.2	1.12	0.31	3728	6534
6	54	1	173	70	1	3.11	2.13	68.6	1.22	6.89	6.48	1.84	0.41	7148	9830
7	65	1	170	91	0	2.79	1.88	67.5	1.29	5.1	2.54	1.48	0.63	6407	5665
8	65	1	160	61	0	2.42	1.53	63	0.84	3.43	2.37	1	0.27	2903	5795
9	57	1	166	79	0	3.75	2.66	71	1.71	6.22	5.33	3	0.51	7361	10312
10	30	1	163	63	0	5.07	3.72	73.3	2.81	8.13	6.63	3.25	1.2	16592	10866
11	58	1	167	67	0	5.38	3.65	67.8	2.02	9.01	7.43	2.9	0.64	18944	22059
12	33	1	174	74	1	4.72	1.94	41	1.68	1.99	1.74	1.65	1.4	7616	8641
13	60	1	173	105	0	3.24	2.43	75	1.84	7.11	5.59	2.47	0.68	8721	7718
14	48	1	180	108	0	4.19	2.39	57.1	1.34	5.08	2.87	1.57	0.6	9365	7472
15	46	1	170	65	1	4.83	3	62	1.33	8.62	5.04	1.86	0.41	15339	11197
16	65	1	156	65	0	2.36	2	84.9	2.73	6.33	6.27	4.28	0.9	2482	4392
17	62	0	153	77	0	2.55	1.72	67.3	1.12	3.36	2.59	1.37	0.49	5150	4158
18	39	1	181	165	0	5.89	4.69	79.5	4.52	7.21	6.71	5.41	2.46	9073	10064
19	58	1	169	78	0	2.36	1.26	53.2	0.67	3.28	1.5	0.71	0.34	3389	3636
20	54	1	178	75	0	5.71	3.1	54.2	1.61	6.23	3.71	1.85	0.76	13664	12884
21	68	1	165	96	0	2.22	1.09	49	0.41	3.4	1.21	0.5	0.2	2559	8099
22	63	1	164	72	0	3.19	2.14	66.9	1.26	4.21	3.2	1.71	0.37	4977	10848
23	57	1	178	81	0	6.11	3.82	62.6	1.96	9.54	7.07	2.77	0.83	11469	22099
24	50	1	168	77	0	2.49	1.37	54.9	0.68	3.92	1.52	0.76	0.37	3614	4926

➤ **مجموعة القياسات الأولى** تتضمن قياسات أجمع الأطباء على أهميتها الأساسية في اتخاذ قرار التشخيص هي:

- 1- FVC: السعة الحيوية القسرية وتقاس بالليتر (L).
- 2- FEV1: حجم الزفير القسري خلال الثانية الأولى من طور الزفير وتقاس بالليتر.
- 3- FEV1/FVC%: النسبة المئوية للقياسين السابقين، ليس لها واحدة.
- 4- FEF25~75%: تدفق الزفير القسري بين 25% و 75% من زمن الزفير، تقاس بالليتر/ثانية.

➤ **مجموعة القياسات الثانية** تتضمن قياسات متعلقة ببنية المريض الفيزيولوجية منها:

- 1- عمر المريض Age: تقاس بوحدة السنة (Year).
- 2- وزن المريض Weight: تقاس بوحدة الكيلو غرام (Kg).

3- طول المريض Height: تقاس بوحدة السنتيمتر (cm).

4- جنس المريض (ذكر أو أنثى): تم اعتماد رقم (1) كون المريض ذكر ورقم (0) كونه أنثى.

5- مدخن أم غير مدخن: تم اعتماد رقم (1) كون المريض مدخن سابق ورقم (0) كونه ليس مدخن.

هذه القياسات يمكن أن تلعب دور في التنبؤ بالقيم الإسمية المرجعية التي يجب أن يتمتع بها المريض حسب احصائيات تم إجراؤها مسبقاً، أي أن القيم نفسها في المجموعة الأولى يمكن أن يكون لها حسب الاحصائيات قيم متباً بها predicted FVC و predicted FEV1 و بقية القياسات الأخرى.

➤ مجموعة القياسات الثالثة تتضمن قياسات ثانوية من حيث الأهمية يرجع لها الطبيب في الحالات الحدية والأكثر تعقيداً مثل:

1- Peak Expiratory Flow (PEF) تدفق الزفير الأعظمي.

2- Max Exp Flow at 25% FVC (MEF25%, MEF50%, MEF75%) تدفق الزفير الأعظمي عند اللحظات 25, 50, 75% من FVC.

3- Forced Expiratory Volume (FEV0.5, FEV2, FEV3) حجم الزفير القسري عند الثانية 0.5 و 2 و 3 على الترتيب.

4- Peak Expiratory Flow Time (PEFT) زمن أعظم تدفق زفير.

5- (FEV2/FVC, FEV3/FVC) نسب الحجم السابقة على حجم FEV.

6- Forced Expiratory Flow (FEF25-50%, FEF 50-75%, FEF75-85%, FEF 0.2-1.2) تدفق الزفير القسري في اللحظات الزمنية المرفقة والمتعلقة بعملية الزفير القسري.

➤ مجموعة القياسات الرابعة تتضمن قياسات معدلة تم استنتاجها من مطال تحويل فورييه لكل من منحنى التدفق-الحجم ومنحنى الحجم-الزمن، يساعد هذين المخططين الأطباء في تحديد جودة تنفيذ الاختبار حيث لكل منهما شكل متفق عليه من أجل قبول الاختبار وإمكانية التشخيص على أساسه وكذلك كيفية كشف الحالات المرضية بانتباه إلى الأشكال وتحديدها والمنحنيات الغريبة فيها كلها تساعد الطبيب في التشخيص. توضح الأشكال (3-6) و (3-7) هذين المنحنيين على الترتيب بينما يوضح الجدول (3-2) أهم القياسات الأساسية في التشخيص.


تعد القياسات الرئيسية الأربعة السابقة أبرز القياسات التي يلجأ إليها الطبيب للحصول على تشخيص للحالة المعروضة ليحدد فيما إذا كان المريض سليماً أو يعاني من علة مرضية يمكن تصنيفها لأصناف مرضية أكثر تحديداً مثل: علة سادة Obstructive Disorder أو قصور Restrictive Disorder أو علة ممزوجة بين الحالتين معاً Mixed Disorder, كما تم ذكره في الفقرة 3-3-1.

بعد فلترة البيانات وانتقاء الأفضل منها حسب رأي الطبيب المختص حصلنا على المجموعات التالية:

- **المجموعة الأولى:** (23p201) 201 عينة كل عينة تتضمن 23 قياس، وقد تم تشخيص هذه العينات من قبل أطباء ذوي خبرة في مجال أمراض الجهاز التنفسي في مشفى الأسد الجامعي- دمشق- وحصلنا على تصنيف بيانات الهدف النهائية لأربعة أصناف: 103 حالة سليمة و 74 حالة مرضية سادة Obstructive و 14 حالة قصور Restrictive و 10 حالات ممزوجة Mixed بين الحالتين المرضيتين السادة والقصيرة.
 - **المجموعة الثانية:** (13p380) 380 عينة تتضمن 13 قياس تضمنت: 122 حالة سليمة، 117 حالة مرض ساد، 76 حالة مرض قصور، 65 حالة مرض مختلط، وقد حصلنا عليها من الشركة الصانعة للجهاز [7].
 - **المجموعة الثالثة:** (25p201) تضمن نفس عدد عينات الأولى 201 ولكن 25 قياس وهي 23 قياس نفس الأولى مع إضافة معاملي مطال تحويل فورييه لكل من مخططي (التدفق-الحجم) و(الحجم-الزمن).
 - **المجموعة الرابعة:** تم انتقاء 276 عينة من العينات السابقة لمقارنة نتائج تصنيف برنامج الجهاز المستخدم في جهاز وظائف الرئة مع نتائج تصنيف الشبكات العصبونية.
- تم تقسيم مجموعات بيانات الدخل الثلاث الأولى السابقة (1 و 2 و 3) عشوائياً: 60% مجموعة التدريب لتعليم الشبكة العصبونية المصممة و 20% مجموعة التوثيق للتحقق من تعميم الشبكة و 20% مجموعة الفحص لحساب دقة تصنيف الشبكة بعد انتهاء التدريب. يوضح الشكل (5-2) توزيع عينات المجموعات الثلاث المستخدمة في هذا البحث حسب أصناف الأمراض المراد تشخيصها.


المجموعة الثانية: 380 عينة ذات 13 قياس

■ Normal ■ Obstructive ■ Restrictive ■ Mixed




المجموعة الأولى والثالثة: 201 عينة ذات 23 أو 25 قياس

■ Normal ■ Obstructive ■ Restrictive ■ Mixed



المجموعة الرابعة: عينات اختبار أداء تصنيف الجهاز تضمنت 276 عينة

■ Normal ■ Obstructive ■ Restrictive ■ Mixed




الشكل (2-5) يبين الشكل اليميني العلوي توزع عينات المجموعة الأولى والثالثة، يبين الشكل اليساري العلوي توزيع المجموعة الثانية، يبين الشكل السفلي توزيع العينات المستخدمة في تقييم دقة تصنيف برنامج الجهاز

3-5 تحليل العينات والمعالجة الأولية



تم دراسة علاقة الترابط بين أهم القياسات وبين الأمراض التي صنفتم إليها، فتم رسم مخططات تشرح خط الميل العام للعينات المصنفة لمجموعة واحدة (مثل حالة سليمة أو مرض انسدادى أو قصور أو مختلط) ومقارنتها مع المجموعات الأخرى لتحديد التداخل في تمييز الأصناف بالنسبة لهذه الأمراض، وذلك من أجل قيم القياسات الأهم والأبرز في التشخيص في حالة تشخيص الطبيب الخبير وفي حالة تشخيص برنامج الجهاز:


1-3-5 تشخيص العينات حسب رأي الطبيب الخبير

تم انتقاء 65 عينة من كل صنف من الأصناف الأربعة ورسم الميول العام لكل صنف لمقارنته مع الأصناف الأخرى واكتشاف أوجه الارتباط بينها كما في الشكل (a3-5) من أجل قياس FVC و (b3-5) من أجل قياس FEV1 و (c3-5) من أجل قياس FEV1% و (d3-5) من أجل قياس FEF:



الشكل (a3-5) مخطط الميول العام لقراءات قيم الـ FVC من أجل العينات المرضى 4×65 وفق الحالات (سليمة، علة سادة، علة قصور، علة مختلطة) حسب تشخيص الطبيب









نلاحظ من المخططات الأربعة [a,b,c,d (3-5)] أنه بشكل عام يمكن الفصل بشكل واضح بين الحالات الطبيعية Normal وبقية الحالات الثلاثة المرضية Obstructive و Restrictive و Mixed, حيث أنه يكون توضع خط الميول للحالات الطبيعية فوق الحالات المرضية دائماً باستثناء مخطط FEV1/FVC في الشكل (c3-5) حيث يتوضع خط ميول عينات الأمراض الانسدادية فوق الحالات الطبيعية (السليمة), أما بالنسبة للحالتين المرضيتين (القاصرة والمختلطة) فتتوضع تحت الحالة الطبيعية دائماً. تعتبر هذه الملاحظات صحيحة من الناحية الطبية التشخيصية لأنه في الحالات التي تكون فيها قيم النسبة المئوية %FEV1/FVC أكبر من قيمة 70~75% (أي الحالة الطبيعية) نكون ضمن احتمالين هما: إما أن يكون المريض سليم أو أن يحمل مرض انسدادى Obstructive, وفي الحالات التي تكون فيها قيمة النسبة %FEV1/FVC أصغر من القيمة 70~75% عندها فإن الحالة المرضية للعينة يمكن أن تتبع أحد احتمالين: حالة مرضية قصور Restrictive أو حالة مرضية مختلطة Mixed.

5-3-2 تشخيص العينات حسب برنامج التشخيص في جهاز PFT

تم انتقاء 50 عينة (تقريباً) من كل صنف من الأصناف الأربعة ورسم الميول العام لكل صنف لمقارنته مع الأصناف الأخرى واكتشاف أوجه الارتباط بينها (لم يتوفر العدد 50 بالنسبة لبعض الأصناف مثل صنف الأمراض المختلطة لذلك تم الاكتفاء بالعدد المتوفر)، كما في الشكل (a4-5) من أجل قياس FVC والشكل (b4-5) من أجل قياس FEV1 والشكل (c4-5) من أجل قياس FEV1% والشكل (d4-5) من أجل قياس FEF:








نلاحظ من المخططات الأربعة [a,b,c,d (4-5)] أنه بشكل عام يمكن الفصل بين الحالات الطبيعية Normal وبقية الحالات الثلاثة المرضية الانسدادية Obstructive والقاصرة Restrictive والمختلطة Mixed ولكن بشكل أقل وضوحاً منه كما هو الحال في التصنيف حسب رأي الطبيب الخبير في الفقرة السابقة [1-3-5], حيث نلاحظ تداخل أكبر بين الحالات المرضية بين بعضها وحتى مع الحالة الطبيعية. ومع ذلك يبقى توضع خط الميول للحالات الطبيعية فوق الحالات المرضية دائماً باستثناء مخطط FEV1/FVC% في الشكل (c4-5) حيث يتوضع خط ميول عينات الأمراض الانسدادية فوق الحالات الطبيعية (السليمة). أما بالنسبة للحالتين المرضيتين (القاصرة والمختلطة) فتتوضع تحت الحالة الطبيعية. تعتبر هذه الملاحظات صحيحة من الناحية الطبية التشخيصية لنفس السبب المذكور مسبقاً في حالة تشخيص الطبيب في الفقرة السابقة [1-3-5]. يمكن أن يعزى هذا التشابه إلى حقيقة أن استراتيجية التشخيص في برنامج الجهاز تستخدم نفس المبدأ المتبع من قبل الطبيب، والاختلاف البسيط في حال حدوثه يمكن أن يعزى إلى أن برنامج الجهاز يتعامل مع حالات غير قابلة للتفاوت (كما هو الحال من طبيب عندما يقرأ بعض الحالات الخاصة في التشخيص التي يمكن أن تبعد قليلاً عن قاعدة التشخيص العامة).

5-4 تحديد نوع الشبكة العصبونية وبنيتها وتحضير البيانات اللازمة لتدريبها

تحدثنا سابقاً في الفصل الرابع عن أنواع الشبكات العصبونية التي يمكن أن تشكل قاعدة الأساس لبناء النموذج اللازم الذي يحقق لنا هدف إيجاد العلاقة الرابطة بين عينات الدخل التي تحدثنا عنها في هذا الفصل مع التشخيص الطبي المقترح من قبل الطبيب الخبير. وبما أن البيانات التي نتعامل معها هي من النوع ثنائيات (Input - Output) أي أننا نعرف مسبقاً الهدف المراد الحصول عليه (الخرج المطلوب) وبالتالي فإن نوع التعليم الموجه Supervised Learning سوف يحقق لنا هذه الغاية مبدئياً. هنالك أنواع

عديدة للشبكات العصبونية ذات التعلم الموجه منها ذات التغذية الأمامية FFN وذات التغذية الخلفية FBN والتكرارية جزئياً Elman وشبكة الذاكرة Hopfield.

بما أن القياسات التي نقيسها من الجهاز وندخلها للشبكة لا تتأثر ببعضها كان من الأنسب عدم إضافة أي روابط داخلية بين عصبونات الطبقة الواحدة وبالتالي استبعاد خيار الشبكات نوع FBN و Elman. كما أن الشبكة المراد الحصول عليها ليست ذاكرة ويجب أن تمتلك قدرة على التعميم وتصنيف البيانات الجديدة التي لم تتدرب عليها مسبقاً لذلك تم استبعاد الشبكات من النوع Hopfield. نستنتج أن الشبكات من النوع FFN هو الأنسب لهذا النوع من التطبيقات والذي هو مستقبلات متعددة الطبقات Multi-



Layer Perceptron (MLP) التي تتصف بنمط التعلم الموجه (Supervised Learning) والقدرة على

التعميم وتصنيف العينات التي لم تتدرب عليها مسبقاً علاوة على قدرتها على التعامل مع العلاقات الغير خطية بفضل توابع التفعيل غير الخطية في كل عصبون من عصبوناتها.

أما بالنسبة للتعليم غير الموجه (Unsupervised Learning) فإننا لم نتطرق إليه في هذا الدراسة لأنه غالباً ما تستخدم هذه الأساليب بشكل أكثر فعالية من أجل معالجة العينات بشكل أولي ليتم إدخالها بشكل مناسب للشبكة ذاتية التعليم، من خلال مثلاً إعادة توزيع عينات الدخل في فضاء بحيث تكون قابلة للفصل (التصنيف) الخطي وغير الخطي. علماً أنه قد تم استخدام مثل هذه الطريقة من أحد المراجع التي ورد ذكرها في الدراسات المرجعية في الفصل الثاني [15].

تحضير البيانات والمعالجة الأولية Preprocessing: تم معالجة قاعدة البيانات المكونة من 201 عينة قبل إدخالها كمدخل للشبكة العصبونية لتكون جاهزة وملئمة لنوع الشبكة المستخدم، تتكون قاعدة البيانات هذه من ثنائيات هي: (دخل - هدف)، الدخل هو شعاع مكون من 23 مركبة هي قياسات محددة لحالة المريض وهي التي تحدد عدد عصبونات طبقة الدخل، بينما الهدف هو شعاع مكون من 4 مركبات هي حالة المريض التي يمكن أن تكون أحد الأصناف التالية: طبيعي، علة حاصرة، علة سادة، علة مركبة وهي التي تحدد عدد عصبونات طبقة الخرج. تشمل عملية المعالجة هذه إعادة توزيع لقيم مركبات العينات بحيث تتراوح بين 0 و 1 أو بين 1 و -1 والتي تعرف Normalization هذه العملية مهمة لتجهيز بيانات الدخل بحيث تتلائم مع نوع الشبكة العصبونية ونوع توابع التحويل حيث أنه في بحثنا قمنا باستخدام كلا الطريقتين وتجربتهما على أنواع وبنى الشبكات العصبونية المختلفة وتقييم النتائج.

نفترض أن لدينا X قيمة المتحول قبل عملية التسوية و Y قيمته بعد التسوية عندها يمكن تطبيق المعادلة (1-5) [11]، وفيها xmin و xmax القيمة الصغرى والعظمى للمتحول قبل التسوية و ymin و ymax القيمة الصغرى والعظمى للمتحول بعد التسوية ومنه:

$$Y = \frac{(y_{max} - y_{min})(X - x_{min})}{(x_{max} - x_{min})} + y_{min} \quad (1 - 5)$$

وبالتالي من أجل إعادة تسوية ضمن المجال $[-1,+1]$ يمكن أن نكتب المعادلة (5-1) بالشكل التالي حسب المعادلة (5-2):

$$Y = \frac{(2)(X - x_{min})}{(x_{max} - x_{min})} - 1 \quad (2 - 5)$$

وعندها قيم Y سوف تتراوح ضمن المجال $[-1,+1]$ مهما كانت قيم X . وبشكل مشابه يمكننا الحصول على معادلة إعادة التسوية من أجل المجال $[0,+1]$ كما في المعادلة (5-3):

$$Y = \frac{(X - x_{min})}{(x_{max} - x_{min})} \quad (3 - 5)$$

5-5 خطة العمل المتبعة لتحصيل النتائج

فيما يلي يعرض الشكل (5-6) المخطط الصندوقي لمراحل بناء الشبكة العصبونية المطلوبة التي تم إجراؤها عملياً لإنجاز هذه الدراسة والحصول على النموذج النهائي للشبكة الذي يلبي الهدف المطلوب:



بناء الشبكة العصبونية Neural Network Construction: يتم في هذه التجربة اختيار متغيرات الشبكة المختلفة والتي يمكن أن تعرض حسب التابع المستخدم في برنامج الماتلاب [11] كالتالي:

$$newpr(P, T, S, TF, BTF, BLF, PF, IPF, OPF, DDF)$$

يتم باستخدام التابع newpr تشكيل شبكة تعرف نماذج Pattern Recognition Network حسب القياسات المدخلة للشبكة حسب التالي:

- P: تمثل مصفوفة بيانات الدخل للشبكة التي سوف تتدرب عليها (عدد عصبونات الدخل).
- T: تمثل مصفوفة بيانات الخرج المطلوب (الهدف) التي ستعمل الشبكة على تصنيف بيانات الدخل إليها (عدد عصبونات الخرج).
- S: تمثل عدد العصبونات في الطبقة المخفية التي يمكن أن تكون طبقة واحدة أو أكثر، ويتم تحديدها بكتابة عدد العصبونات في كل طبقة مخفية كالتالي:

[Hidden1 Hidden2 Hidden3]

- TF: تمثل تابع التحويل (التفعيل) في كافة طبقات الشبكة العصبونية التي يمكن أن تحدد حسب الترتيب التالي: {'input' 'hidden1' 'hidden2' 'output'} (يمكن أن تحتوي الطبقات المخفية أكثر من نوع لتابع التحويل). وبالتالي يمكن اختبار أي نوع من توابع التفعيل الواردة في الجدول (2-4) لعصبونات كل طبقة، مثلاً يمكن كتابة tansig للدلالة على تابع التفعيل القطعي و logsig للدلالة على تابع التفعيل اللوغاريتمي. مع الأخذ بعين الاعتبار من أجل طبقة الدخل أن التوابع tansig تتناسب مع نموذج التسوية [-1,+1] بينما التوابع logsig تتناسب مع التسوية [0,+1] ومنه يمكننا تجهيز توابع التفعيل للطبقات وفق:

{'logsig' 'tansig' 'purelin'}

- BTF: تمثل تابع خوارزمية التدريب المستخدمة في طريقة الانتشار التراجعي، ويتم اختبار نوع خوارزمية التدريب التي سوف تحدد مراحل تعديل الأوزان والانزياحات وحساب الأخطاء وأسلوب التوقف. يمكن اختبار أي خوارزمية من الجدول (4-1) بكتابة train ورمز الخوارزمية مثلاً من أجل خوارزمية Levenberg Marquardt: 'trainlm'. وبالتالي عند

اختيار نوع معين من الخوارزميات مثل 'trainlm' يمكن أن نعدل أي خاصية من خواصها مع العلم أنها تحوي قيم افتراضية مسبقاً مثل:

1- عدد عصور التدريب Epochs افتراضياً تكون 1000 ويمكن أن تتغير حسب الحاجة، أحياناً زيادة عصور التدريب يمكن أن يزيد من كفاءة تدريب الشبكة في حال استمرار تناقص الخطأ ولكن أحياناً أخرى يمكن أن يزيد زمن التدريب دون فائدة.

2- معدل التعلم Learning Rate: يجب أن يتحدد بقيمة تقع بين [0,1] وبشكل افتراضي تكون هذه القيمة 0.001 في خوارزمية LM و SCG وتكون 0.005 في خوارزمية BR و 0.07 في خوارزمية RP، ويمكن أن يتغير حسب سلوك عملية التدريب وحساب الخطأ وفق المتغيرات المتعلقة بخطوة زيادة معدل التعلم 10 و خطوة نقصان معدل التعلم 0.1 بحيث لا تقع الشبكة في مشاكل عدم استقرار عملية التدريب أو زيادة زمن تقارب الخوارزمية.

3- قيمة الخطأ الأصغرية المراد تحقيقها $GOAL=0$.

4- العدد الأعظمي لاختبار مجموعة التوثيق $max_fail=100$: بشكل افتراضي تكون هذه القيمة مساوية 6 وقد قمنا بتعديلها لتصبح 100 حتى تتمكن الخوارزمية من إجراء عدد أكبر من الاختبارات قبل انتهاء التدريب وبالتالي إمكانية تحقيق خطأ أصغر.

➤ BLF: تمثل تابع خوارزمية المستخدمة في تعديل الأوزان والانزياحات لكافة العصبونات في الشبكة التي يتم تدريبها وفق أسلوب الانتشار التراجعي.

➤ PF: تمثل تابع حساب الخطأ المستخدم في تحديد قيمة الخطأ الناتج خلال عملية التدريب والتي بناءً عليها يتم تعديل الأوزان والانزياحات لعصبونات الشبكة. وقمنا باستخدام تابعين MSE و SSE حسب المعادلتين (4-19) و (4-20) اللتان تم شرحهما في الفصل الرابع.

➤ IPF: تمثل توابع المعالجة الأولية لبيانات الدخل المستخدمة لتجهيز بيانات الدخل للشبكة، قمنا باستخدام تابع التسوية mapminmax لإعادة تسوية قيم كل متغير وفق المجال [-1,+1] والمجال [+1,0].

➤ OPF: تمثل توابع المعالجة النهائية لخرج الشبكة العصبونية، ولم يكن هنالك حاجة لمعالجة الخرج.

➤ DF: تمثل تابع تقسيم البيانات المدخلة للشبكة (تدريب - توثيق - اختبار)، قمنا باستخدام تابع تقسيم البيانات بشكل تناوبي interleaved لثلاثة مجموعات 60% للتدريب و20% للتوثيق و20% للفحص. بشكل تناوبي أي الانتقال الأول يكون لمجموعة التدريب والذي يليه لمجموعة التوثيق والذي يليه لمجموعة الفحص وهكذا.

بعد أن قمنا ببناء النموذج الأولي للشبكة العصبونية وجدنا أنه هنالك العديد من المتغيرات التي يمكن أن تحسن في نتائج الشبكة العصبونية التي يتم تكوينها، أي تغيير في أحد المتغيرات داخل أقواس التابع newpr يمكن أن يغير في هذه النتائج سلباً أو إيجاباً [11]، لذلك تم الاعتماد على تقسيم مراحل البحث كالتالي:

1) مرحلة التغيير في متغيرات الدخل P,T حيث أن التغيير في بيانات الدخل والهدف من حيث زيادة

عدد العينات أو حتى زيادة عدد مركبات العينة الواحدة يمكن أن يحسن في نتائج الشبكة العصبونية بشكل كبير كما أن المعالجة الأولية لهذه البيانات يمكن أن تؤثر بالمثل، لذلك تم معالجة قاعدة بيانات العينات المستحصلة بعدة طرق منها:

1- 201 عينة كل عينة مكونة من 23 مركبة (المجموعة الأولى): تم معالجتها وإعادة تسوية قيم المركبات بين قيمتي [0,1].

2- 201 عينة كل عينة مكونة من 23 مركبة (المجموعة الأولى): تم معالجتها وإعادة تسوية قيم المركبات بين قيمتي [-1,1].

3- 380 عينة كل عينة مكونة من 13 مركبة (المجموعة الثانية): تم معالجتها وإعادة تسوية قيم المركبات بين قيمتي [0,1].

4- 380 عينة كل عينة مكونة من 13 مركبة (المجموعة الثانية): تم معالجتها وإعادة تسوية قيم المركبات بين قيمتي [-1,1].

ينبغي الانتباه عند تغيير قيمة التسوية للمركبات Normalization إلى توابع التحويل المستخدمة في العصبونات بخاصة عصبونات الطبقة المخفية, فعندما تكون القيم محصورة بين [0,1] من المستحسن أن تكون توابع التحويل TF من النوع "logsig" توابع تحويل لوغاريتمية أما عندما تكون القيم محصورة بين [-1,1] يستحسن أن تكون توابع التحويل من النوع "tansig" أي تظل زاوية.

(2) مرحلة التغيير في عدد عصبونات الطبقات المخفية المستخدمة في الشبكة في الحالتين التاليتين:

1- حالة طبقة مخفية واحدة: تم تغيير عدد العصبونات من 2 عصبون إلى 100 عصبون وتقييم نتائج الشبكة وحساب نسبة التصنيف الصحيح للعينات في حالة عينات التدريب وعينات الفحص عند كل عدد من الأعداد الواقعة ضمن المجال السابق.

2- حالة طبقتين مخفيتين: تم تغيير عدد العصبونات في الطبقة الأولى من 2 عصبون إلى 50 عصبون والطبقة الثانية من 2 عصبون إلى 30, وقد تم تقييم نتائج الشبكة وحساب نسبة التصنيف الصحيح للعينات في حالة عينات التدريب وعينات الفحص عند كل عدد من الأعداد الواقعة ضمن المجالين السابقين.

تم الإعتماد في تحديد عدد العصبونات الكافي بناءً على المعادلة (4-11) في حالة طبقة مخفية واحدة:

$$2\sqrt{(m+2)N}$$

حيث أن m تدل على عدد مخارج الشبكة العصبونية وهي في بحثنا 4 و تدل N على عدد العينات المدخلة للشبكة أثناء عملية التدريب وبالتالي يكون العدد الكافي لعصبونات الطبقة المخفية بشكل تقريبي 60 عصبون [12].

أما في حالة استخدام طبقتين مخفيتين في الشبكة العصبونية فيمكن الاعتماد على القانون التالي لحساب العدد التقريبي لعصبونات الطبقات المخفية كما في المعادلتين (4-12) و (4-13) [12]:
في الطبقة المخفية الأولى:

$$\sqrt{(m+2)N} + 2\sqrt{N/(m+2)}$$

في الطبقة المخفية الثانية:

$$m\sqrt{N/(m+2)}$$


وبالتالي في الطبقة المخفية الأولى يمكن أن يكون العدد الكافي للعصبونات تقريباً 40 وفي الطبقة المخفية الثانية تقريباً 20.

لم نتطرق إلى أكثر من طبقتين مخفيتين لأن المشكلة المطروحة لا تتطلب هذا القدر من التعقيد، وأي نظام غير خطي مهما كان معقداً يمكن أن يكتفي بطبقتين مخفيتين لتمثيله بشكل تقريبي مقبول. وكما ورد في [8] يمكن لشبكة عصبونية بطبقة مخفية واحدة تقريب Approximation أي تابع $F(x_1, \dots, x_n)$ مهما كان معقد بخطأ $\varepsilon > 0$.

(3) مرحلة التغير في خوارزمية التدريب المتبعة في الشبكة لانجاز الانتشار التراجعي Back-Propagation: مع كل نوع من أنواع الخوارزميات المقترحة في الجدول (4-1) تم تغيير عدد عصبونات الطبقات المخفية حسب المجال المقترح مسبقاً بالإضافة إلى استخدام طبقتين مخفيتين أيضاً وتغيير عدد العصبونات فيهما معاً حسب المجالات المقترحة.

(4) مرحلة إضافة معاملين جديدين للقياسات ذات 23 مركبة (عينات=201) لم يتم استخدامهما مسبقاً في الأبحاث مأخوذين من مطالي تحويل فورييه لكل من مخططي (التدفق-الحجم) و(الحجم-الزمن) المستحصلين من تقرير المريض ليصبح عدد قياسات العينة الواحدة 25 مركبة، وتم تقييم النتائج في كافة الحالات السابقة (أي بتغيير الخوارزميات والطبقات وعدد العصبونات وأسلوب إعادة التسوية).

نلخص في الشكل (5-7) المراحل التي تم من خلالها إجراء كافة التغيرات السابقة للحصول على أفضل النتائج وبالتالي الحصول على أفضل نموذج للشبكة العصبونية المطلوبة، يوضح الملحق الأول برنامج تدريب وفحص الشبكة العصبونية المصممة باستخدام بيئة عمل الماتلاب.



تم تكرار عملية تدريب الشبكة العصبونية المصممة عدد كبير من المرات بحيث تشمل الخوارزميات الممكنة المعروضة في الجدول (4-1)، وتم أيضاً تدريب الشبكة بحيث تشمل جميع احتمالات عدد العصبونات في الطبقات المخفية وفق المجالات التي تم حسابها من المعادلات (4-11) و (4-12) و (4-13) في الفقرات السابقة فحصلنا على المجال [2, 100] من أجل الطبقة المخفية الواحدة، والمجال [2, 50] في الطبقة المخفية الأولى و [2, 30] في الطبقة المخفية الثانية في الشبكة ثنائية الطبقة المخفية. يلي ذلك اختيار أفضل عدد عصبونات يعطي أفضل أداء (دقة) تصنيف للشبكة العصبونية لنحصل على جداول من القيم التي سوف يرد ذكرها لاحقاً حسب مجموعة بيانات الدخل. بعد ذلك تحليل هذه الجداول لاختيار الأفضل منها ودراسته وفق معايير قياس الأداء المذكورة في الفصل الرابع، ثم عرض بعض الأمثلة لأفضل النتائج وفي النهاية عرض لمزايا استخدام تقنية التوقف المبكر.

5-5-1 التجربة الأولى: تدريب الشبكة على مجموعة بيانات الدخل 201 عينة بـ 23 مركبة

حصلنا من التجربة الأولى على الجداول (a2-5) و (b2-5) و (c2-5) و (d2-5) بالاعتماد على النموذج الأول الذي عملنا على بنائه وتحديد متغيراته في الفقرة السابقة إضافة إلى التغيير في عدد عصبونات الطبقات المخفية (أحادية أو ثنائية)، آخذين بعين الاعتبار أن عدد عصبونات طبقة الدخل يتعلق بأبعاد عينة الدخل وهي 23 وعدد عصبونات طبقة الخرج هي 4 حالات التصنيف.

الجدول (a2-5) نتائج التجربة الأولى لأفضل بنية شبكة عصبونية MLP مع بيانات للدخل 23×201 وإعادة تسوية [-1,+1] وطبقتين مخفيتين وتغيير عدد العصبونات في الطبقة الأولى وفق المجال [2,50] والطبقة الثانية [2,30] مع توابع تفعيل من النوع القطعي لكل عصبونات الطبقات

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية 1	عدد عصبونات طبقة مخفية 2	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	5	17	97.35	86
2	Bayesian Regularization Backpropagation	6	28	97.35	84
3	Scaled Conjugate Gradient Backpropagation	34	27	96.96	84
4	Resilient Backpropagation	33	29	97.35	88
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	25	29	95.36	86
6	Polak-Ribiere Conjugate Gradient Backpropagation	32	26	96.96	86
7	One Step Secant Backpropagation	15	21	95.36	80
8	Fletcher-Powell Conjugate Gradient Backpropagation	50	25	96.03	84
9	Powell-Beale Conjugate Gradient Backpropagation	48	30	97.35	84
10	Gradient Descent with Adaptive Learning Rule	22	28	95.36	86
11	Gradient Descent Backpropagation	45	24	90.07	80
12	Sequential Order Incremental Training with Learning Functions	14	2	85.43	82

الجدول (b2-5) نتائج التجربة الأولى لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 23×201 وإعادة تسوية [0,+1] وطبقتين مخفيتين وتغيير عدد العصبونات في الطبقة الأولى وفق المجال [2,50] والطبقة الثانية [2,30] مع توابع تفعيل من النوع القطعي للطبقة المخفية والخرج ولوغاريتمية لطبقة الدخل

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية 1	عدد عصبونات طبقة مخفية 2	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	26	6	96.69	86
2	Bayesian Regularization Backpropagation	5	16	96.03	86
3	Scaled Conjugate Gradient Backpropagation	56	14	96.03	84
4	Resilient Backpropagation	41	20	96.69	88
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	20	30	96.03	84
6	Polak-Ribiere Conjugate Gradient Backpropagation	10	23	94.7	84
7	One Step Secant Backpropagation	7	25	94.04	84
8	Fletcher-Powell Conjugate Gradient Backpropagation	35	27	94.7	82
9	Powell-Beale Conjugate Gradient Backpropagation	8	14	96.03	84
10	Gradient Descent with Adaptive Learning Rule	14	23	91.39	82
11	Gradient Descent Backpropagation	6	18	88.74	74
12	Sequential Order Incremental Training with Learning Functions	17	28	79.47	74

الجدول (c2-5) نتائج التجربة الأولى لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 23×201 وإعادة تسوية $[-1, +1]$ مع طبقة مخفية وحيدة وتغيير عدد العصبونات فيها وفق المجال $[2, 100]$ مع توابع تفعيل من النوع القطعي لكل عصبونات الطبقات

#	اسم الخوارزمية	عدد عصبونات الطبقة المخفية	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	45	96.69	80
2	Bayesian Regularization Backpropagation	16	96.03	84
3	Scaled Conjugate Gradient Backpropagation	6	95.36	84
4	Resilient Backpropagation	51	96.03	88
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	79	94.7	86
6	Polak-Ribiere Conjugate Gradient Backpropagation	35	92.72	78
7	One Step Secant Backpropagation	63	94.04	82
8	Fletcher-Powell Conjugate Gradient Backpropagation	81	92.72	78
9	Powell-Beale Conjugate Gradient Backpropagation	69	93.38	84
10	Gradient Descent with Adaptive Learning Rule	65	91.39	82
11	Gradient Descent Backpropagation	100	88.74	80
12	Sequential Order Incremental Training with Learning Functions	12	74.17	78

الجدول (d2-5) نتائج التجربة الأولى لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 23×201 وإعادة تسوية [0,+1] مع طبقة مخفية وحيدة وتغيير عدد العصبونات فيها وفق المجال [2,100] مع توابع تفعيل من النوع القطعي للخروج والمخفي ولوغاريتمية لطبقة الدخل

#	اسم الخوارزمية	عدد عصبونات الطبقة المخفية	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	63	96.69	82
2	Bayesian Regularization Backpropagation	78	97.35	84
3	Scaled Conjugate Gradient Backpropagation	31	93.38	84
4	Resilient Backpropagation	79	93.36	82
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	31	94.04	88
6	Polak-Ribiere Conjugate Gradient Backpropagation	27	92.72	78
7	One Step Secant Backpropagation	78	90.73	78
8	Fletcher-Powell Conjugate Gradient Backpropagation	96	92.05	82
9	Powell-Beale Conjugate Gradient Backpropagation	84	92.05	76
10	Gradient Descent with Adaptive Learning Rule	7	90.07	82
11	Gradient Descent Backpropagation	78	87.42	74
12	Sequential Order Incremental Training with Learning Functions	29	83.44	62

نلاحظ من الجداول الأربعة السابقة [a,b,c,d (2-5)] أن أفضل الخوارزميات التي تعطي أعلى دقة تصنيف بالنسبة لمجموعة البيانات الأولى هي الخوارزميات التالية بالترتيب حسب الجدول (a2-5) مع تركيب بنية الشبكة العصبونية (عدد العصبونات في كل طبقة حسب الترتيب من اليمين إلى اليسار: طبقة الخرج - الطبقة المخفية 2- الطبقة المخفية 1 - طبقة الدخل) ودقة التصنيف:

- 1) خوارزمية Resilient Back-propagation (RP): وفق بنية [23-33-29-4] ودقة تصنيف 88%.
 - 2) خوارزمية Levenberg Marquardt (LM): وفق بنية [23-5-17-4] ودقة تصنيف 86%.
 - 3) خوارزمية Bayesian Regularization (BR): وفق بنية [23-6-28-4] ودقة تصنيف 84%.
 - 4) خوارزمية Scaled Conjugate Gradient (SCG): وفق بنية [23-34-27-4] ودقة تصنيف 84%.
- حيث سجلت هذه الخوارزميات دقة تصنيف أفضل من بقية الخوارزميات بقيمة تتراوح من 2% إلى 32% (تم حساب هذا المجال عن طريق مقارنة أعلى دقة بين الخوارزميات الأربعة مع أعلى دقة من بقية الخوارزميات ومقارنة أدنى دقة من الخوارزميات الأربعة مع أدنى دقة من بقية الخوارزميات) وبزمن تدريب أقصر من بقية الخوارزميات بقيمة تتراوح من 2 إلى 15 أضعاف الزمن اللازم لتقارب الخوارزمية على مجموعة البيانات الأولى.

5-5-2 التجربة الثانية: تدريب الشبكة على مجموعة بيانات الدخل 380 عينة بـ 13 مركبة

تم تطبيق نفس بنية الشبكة العصبونية وطريقة الاختبار التي تم انجازها مسبقاً على بيانات دخل ولكن بعدد عينات أكبر وعدد أبعاد عينة أقل بالأخذ بعين الاعتبار تغيير عدد عصبونات طبقة الدخل مع تغيير عدد أبعاد العينة حيث في التجربة الأولى كان 23 أما في الثانية فهو 13. أعطت هذه التجربة النتائج حسب الجداول (a3-5) و (b3-5) و (c3-5) و (d3-5):

الجدول (a3-5) نتائج التجربة الثانية لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 13×380، وإعادة تسوية [-1,+1] وطبقتين مخفيتين وتغيير عدد العصبونات في الطبقة الأولى وفق المجال [2,50] والطبقة الثانية [2,30] مع توابع تفعيل من النوع القطعي لكل عصبونات الطبقات

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية 1	عدد عصبونات طبقة مخفية 2	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	7	24	97.19	84.21
2	Bayesian Regularization Backpropagation	7	25	96.14	82.11
3	Scaled Conjugate Gradient Backpropagation	36	19	96.14	87.95
4	Resilient Backpropagation	19	16	95.79	81
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	47	23	94.74	85
6	Polak-Ribiere Conjugate Gradient Backpropagation	36	24	95.79	79
7	One Step Secant Backpropagation	32	11	96.14	76
8	Fletcher-Powell Conjugate Gradient Backpropagation	17	14	94.74	83
9	Powell-Beale Conjugate Gradient Backpropagation	30	6	95.79	79
10	Gradient Descent with Adaptive Learning Rule	23	3	94.74	80
11	Gradient Descent Backpropagation	48	18	82.46	85
12	Sequential Order Incremental Training with Learning Functions	40	30	78.6	79

الجدول (b3-5) نتائج التجربة الثانية لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 13×380 , وإعادة تسوية $[0,+1]$ وطبقتين مخفيتين وتغيير عدد العصبونات في الطبقة الأولى وفق المجال $[2,50]$ والطبقة الثانية $[2,30]$ مع توابع تفعيل من النوع القطعي للطبقة المخفية والخرج ولوغاريتمية للطبقة الدخل

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية 1	عدد عصبونات طبقة مخفية 2	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	7	19	96.14	80
2	Bayesian Regularization Backpropagation	20	28	96.14	80
3	Scaled Conjugate Gradient Backpropagation	24	4	95.79	80
4	Resilient Backpropagation	30	19	95.79	80
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	13	16	94.39	82
6	Polak-Ribiere Conjugate Gradient Backpropagation	16	14	95.09	83
7	One Step Secant Backpropagation	35	6	94.39	84
8	Fletcher-Powell Conjugate Gradient Backpropagation	20	22	93.33	83
9	Powell-Beale Conjugate Gradient Backpropagation	24	25	95.09	81
10	Gradient Descent with Adaptive Learning Rule	14	6	90.53	87
11	Gradient Descent Backpropagation	32	22	78.95	81
12	Sequential Order Incremental Training with Learning Functions	33	27	78.6	83

الجدول (c3-5) نتائج التجربة الثانية لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 13×380 , وإعادة تسوية $[-1, +1]$ مع طبقة مخفية وحيدة وتغيير عدد العصبونات فيها وفق المجال $[2, 100]$ مع توابع تفعيل من النوع القطعي لكل عصبونات الطبقات

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	45	94.04	83
2	Bayesian Regularization Backpropagation	8	92.98	85.26
3	Scaled Conjugate Gradient Backpropagation	18	93.33	83.16
4	Resilient Backpropagation	35	93.68	86.32
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	53	93.68	85.26
6	Polak-Ribiere Conjugate Gradient Backpropagation	50	91.93	81
7	One Step Secant Backpropagation	43	91.93	85.26
8	Fletcher-Powell Conjugate Gradient Backpropagation	31	90.88	84.21
9	Powell-Beale Conjugate Gradient Backpropagation	90	91.93	81
10	Gradient Descent with Adaptive Learning Rule	58	91.18	85.26
11	Gradient Descent Backpropagation	73	80.7	86.32
12	Sequential Order Incremental Training with Learning Functions	23	72.98	74.74

الجدول (d3-5) نتائج التجربة الثانية لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 13×380، وإعادة تسوية [0,+1] مع طبقة مخفية وحيدة وتغيير عدد العصبونات فيها وفق المجال [2,100] مع توابع تفعيل من النوع القطعي للخرج والمخفي ولوغاريتمية لطبقة الدخل

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	87	95.09	78.95
2	Bayesian Regularization Backpropagation	99	95.09	80
3	Scaled Conjugate Gradient Backpropagation	2	93.68	84.21
4	Resilient Backpropagation	82	94.74	78.95
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	17	93.33	84.21
6	Polak-Ribiere Conjugate Gradient Backpropagation	61	93.68	84.21
7	One Step Secant Backpropagation	49	92.63	85.26
8	Fletcher-Powell Conjugate Gradient Backpropagation	82	90.88	83.16
9	Powell-Beale Conjugate Gradient Backpropagation	12	92.98	85.26
10	Gradient Descent with Adaptive Learning Rule	81	86.67	80
11	Gradient Descent Backpropagation	24	77.89	77.89
12	Sequential Order Incremental Training with Learning Functions	22	75.44	77.89

نلاحظ من الجداول الأربعة السابقة [a,b,c,d (3-5)] أن أفضل الخوارزميات التي تعطي أعلى دقة تصنيف بالنسبة لمجموعة البيانات الثانية هي الخوارزميات التالية بالترتيب حسب الجدول (a3-5) مع تركيب بنية الشبكة العصبونية (عدد العصبونات في كل طبقة حسب الترتيب من اليمين إلى اليسار: طبقة الخرج - الطبقة المخفية 2- الطبقة المخفية 1 - طبقة الدخل) ودقة التصنيف:

- 1) خوارزمية Scaled Conjugate Gradient (SCG): وفق بنية [23-36-19-4] ودقة تصنيف 88%.
 - 2) خوارزمية Levenberg Marquardt (LM): وفق بنية [23-7-24-4] ودقة تصنيف 84.2%.
 - 3) خوارزمية Bayesian Regularization (BR): وفق بنية [23-7-25-4] ودقة تصنيف 82.1%.
 - 4) خوارزمية Resilient Back-propagation (RP): وفق بنية [23-19-16-4] ودقة تصنيف 81%.
- حيث سجلت هذه الخوارزميات دقة تصنيف أفضل من بقية الخوارزميات بقيمة تتراوح من 2.5% إلى 10% وذلك من أجل الجدولين [a,c (3-5)] حيث كانت هذه الخوارزميات الأربعة متقدمة على البقية، أما في الجدولين الآخرين [b,d (3-5)] تراجت دقة تصنيف هذه الخوارزميات بقيمة تتراوح من 1% إلى 5% لسبب يمكن أن يعزى إلى أن نمط تسوية البيانات [0,1] المستخدم في الجدولين [b,d (3-5)] لم يتناسب مع الخوارزميات الأربعة (تم حساب هذا المجال عن طريق مقارنة أعلى دقة بين الخوارزميات الأربعة مع أعلى دقة من بقية الخوارزميات ومقارنة أدنى دقة من الخوارزميات الأربعة مع أدنى دقة من بقية الخوارزميات)، كما أن زمن تدريب الخوارزميات الأربعة أقصر من أزمنة بقية الخوارزميات بقيمة تتراوح من 3 إلى 9 أضعاف الزمن اللازم لتقارب الخوارزمية على مجموعة البيانات الثانية.

3-5-5 التجربة الثالثة: تدريب الشبكة على مجموعة بيانات الدخل 201 عينة بـ 25 مركبة


بنفس الطريقة السابقة فقد تم حساب مطال تحويل فورييه لمخطط (التدفق-الحجم) ومطال تحويل فورييه لمخطط (الحجم-الزمن) حسب الجدول (4-5). تم إضافة المعاملين الجديدين المقترحين إلى مجموعة البيانات الأولى (لكل عينة بحيث يصبح عدد قياسات كل عينة 25) وإعادة خطوات البحث السابقة كلها والحصول على الجداول والمخططات، ثم إجراء المقارنة قبل وبعد إضافة هذين المعاملين المقترحين.


الجدول (4-5) خطوات حساب مطال تحويل فورييه على عينة مخطط التدفق مع الحجم: يقوم التابع FFT بإجراء تحويل فورييه لقيم التدفق ثم حساب مطال الأعداد العقدية الناتجة على حدى باستخدام التابع ABS ثم جمع كافة المطالات للحصول على مطال كلي باستخدام التابع SUM

قيم منحنى التدفق (العينة 1)	تحويل فورييه لقيم منحنى التدفق	الطاقة الطيفية لتحويل فورييه لكل قيمة من المنحنى	مجموع كل قيم الطاقة الطيفية
0.966	665.009+ 0.0i	665.009	2185.674231
0.988	-292.547 + 9.169i	292.6904064	
0.977	105.948 + 127.601i	165.8524851	
0.966	27.737 - 58.388i	64.64085114	
0.828	-25.76538 + 6.191i	26.49858402	
0.782	11.881 + 17.531i	21.17673127	
0.736	8.249 - 10.797i	13.58798554	
.	.	.	
.	.	.	
.	.	.	
1.018	-0.231 + 0.599i	0.64212009	
.	.	.	
.	.	.	
.	.	.	
4.827	-0.0917 + 0.312i	0.325629238	
4.793	0.162 - 0.208i	0.264138118	
.	.	.	
.	.	.	
.	.	.	
3.802	-0.225 + 0.24i	0.329057001	
3.765	0.0973 + 0.0852i	0.129347938	
.	.	.	
.	.	.	
.	.	.	
1.14	105.948 - 127.601i	165.8524851	
1.139	-292.5468 - 9.1685i	292.6904064	

تم حساب تحويل فورييه لقيم مخطط التدفق (ومخطط الحجم أيضاً) حسب المعادلة (4-24) باستخدام تابع الماتلاب [fft] ثم حساب المطال لكل قيمة على حدى باستخدام تابع الماتلاب [abs] ثم جمع كافة القيم لنحصل على قيمة واحدة محددة للعينة الواحدة باستخدام تابع الماتلاب [sum]. كما وتم دراسة ترابط مطال تحول فورييه هذه من خلال رسم مخططات ميول هذه القيم حسب تصنيفها بين الحالات الأربعة

المقترحة (الحالة السليمة- المرض الانسدادي- مرض القصور- المرض المختلط) لكل من مخططي (تدفق-حجم) و(حجم-زمن) كما هو معروض في الشكل (5-8) و (5-9) على الترتيب. حيث نلاحظ من الشكلين إمكانية فصل بين خط ميول الحالات السليمة عن الحالات المرضية دائماً، كما يمكن أيضاً فصل المرض الانسدادي عن المرضين الآخرين (القاصر والمختلط)، بينما يوجد صعوبة فصل المرضين (القاصر والمختلط) عن بعضهما.





الشكل (5-9) مطال تحويل فورييه لمخططات التنفس "الحجم مع الزمن" من أجل العينات المرضى 4×65 وفق الحالات (سليمة، علة سادة، علة قصور، علة مختلطة) حسب تشخيص الطبيب

تم استخدام النموذج الأول الذي عملنا على بناؤه وتحديد متغيراته في التجربة الأولى الفقرة 5-5-1 من حيث التغيير في عدد عصبونات الطبقات المخفية (أحادية أو ثنائية)، آخذين بعين الاعتبار أن عدد عصبونات طبقة الدخل يتعلق بأبعاد عينة الدخل التي هي في التجربة الثالثة 25 بعد إضافة مطالي تحويل فورييه إلى 23 قياس. بينما لم يتغير عدد عصبونات طبقة الخرج والذي هو 4 عدد حالات التصنيف. تم اتباع كامل الخطوات في التجربة الأولى باستثناء إضافة المعاملين الجديدين (مطال تحويل فورييه) حتى يتسنى لنا المقارنة بشكل دقيق وكشف الاختلاف قبل وبعد إضافة هذين المعاملين من حيث تحسين أو انخفاض أداء الشبكة (دقة تصنيف) على عينات الفحص. توضح الجداول (a5-5) و (b5-5) و (c5-5) و (d5-5) النتائج التي حصلنا عليها من تدريب الشبكة العصبونية على مجموعة البيانات الثالثة:

الجدول (a5-5) نتائج التجربة الثالثة لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 25×201 تحويل معاملين تحويل فورييه الإضافيين، وإعادة تسوية $[-1, +1]$ وطبقتين مخفيتين وتغيير عدد العصبونات في الطبقة الأولى وفق المجال $[2, 50]$ والطبقة الثانية $[2, 30]$ مع توابع تفعيل من النوع القطعي لكل عصبونات الطبقات

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية 1	عدد عصبونات طبقة مخفية 2	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	2	3	96.69	84
2	Bayesian Regularization Backpropagation	8	11	96.69	86
3	Scaled Conjugate Gradient Backpropagation	48	11	95.36	88
4	Resilient Backpropagation	23	17	96.69	90
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	38	16	95.36	82
6	Polak-Ribiere Conjugate Gradient Backpropagation	44	13	96.03	86
7	One Step Secant Backpropagation	24	24	95.36	86
8	Fletcher-Powell Conjugate Gradient Backpropagation	27	10	92.72	88
9	Powell-Beale Conjugate Gradient Backpropagation	31	17	96.03	84
10	Gradient Descent with Adaptive Learning Rule	26	15	93.38	88
11	Gradient Descent Backpropagation	42	17	91.39	82
12	Sequential Order Incremental Training with Learning Functions	7	11	82.78	80

الجدول (b5-5) نتائج التجربة الثالثة لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 25×201 تحويل معاملين تحويل فورييه الإضافيين، وإعادة تسوية $[0, +1]$ وطبقتين مخفيتين وتغيير عدد العصبونات في الطبقة الأولى وفق المجال $[2, 50]$ والطبقة الثانية $[2, 30]$ مع توابع تفعيل من النوع القطعي للطبقة المخفية وطبقة الخرج ولوغاريتمية لطبقة الدخل

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية 1	عدد عصبونات طبقة مخفية 2	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	9	3	96.69	86
2	Bayesian Regularization Backpropagation	2	27	97.35	78
3	Scaled Conjugate Gradient Backpropagation	17	19	94.04	80
4	Resilient Backpropagation	28	7	96.69	84
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	17	19	94.7	86
6	Polak-Ribiere Conjugate Gradient Backpropagation	9	27	94.7	82
7	One Step Secant Backpropagation	28	13	93.38	82
8	Fletcher-Powell Conjugate Gradient Backpropagation	28	28	92.05	82
9	Powell-Beale Conjugate Gradient Backpropagation	16	23	94.7	82
10	Gradient Descent with Adaptive Learning Rule	7	26	92.72	82
11	Gradient Descent Backpropagation	11	18	87.42	78
12	Sequential Order Incremental Training with Learning Functions	27	26	82.12	76

الجدول (c5-5) نتائج التجربة الثالثة لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 25×201 تحويل معاملين تحويل فورييه الإضافيين، وإعادة تسوية [-1,+1] مع طبقة مخفية واحدة مع توابع تفعيل من النوع القطعي لكل عصبونات الطبقات

#	اسم الخوارزمية	عدد عصبونات الطبقة المخفية	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	43	95.36	82
2	Bayesian Regularization Backpropagation	2	95.36	84
3	Scaled Conjugate Gradient Backpropagation	91	92.72	80
4	Resilient Backpropagation	32	95.36	90
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	37	92.72	86
6	Polak-Ribiere Conjugate Gradient Backpropagation	16	94.04	88
7	One Step Secant Backpropagation	48	91.39	80
8	Fletcher-Powell Conjugate Gradient Backpropagation	71	92.05	76
9	Powell-Beale Conjugate Gradient Backpropagation	54	92.05	80
10	Gradient Descent with Adaptive Learning Rule	51	92.05	82
11	Gradient Descent Backpropagation	98	88.08	82
12	Sequential Order Incremental Training with Learning Functions	77	78.15	64

الجدول (d5-5) نتائج التجربة الثالثة لأفضل بنية شبكة عصبونية MLP وقاعدة بيانات للدخل 25×201 تحويل معاملين تحويل فورييه الإضافيين، وإعادة تسوية [0,+1] مع طبقة مخفية واحدة مع توابع تفعيل من النوع القطعي للخرج والمخفي ولوغاريتمية لطبقة الدخل

#	اسم الخوارزمية	عدد عصبونات طبقة مخفية	نتائج التدريب (%)	نتائج الفحص (%)
1	Levenberg Marquardt Backpropagation	76	95.36	86
2	Bayesian Regularization Backpropagation	9	94.7	88
3	Scaled Conjugate Gradient Backpropagation	79	90.7	82
4	Resilient Backpropagation	75	94.7	88
5	Gradient Descent with Momentum and Adaptive learning rate rule Backpropagation	39	93.38	88
6	Polak-Ribiere Conjugate Gradient Backpropagation	72	90.73	82
7	One Step Secant Backpropagation	12	90.07	78
8	Fletcher-Powell Conjugate Gradient Backpropagation	17	91.39	78
9	Powell-Beale Conjugate Gradient Backpropagation	15	92.05	84
10	Gradient Descent with Adaptive Learning Rule	19	90.73	82
11	Gradient Descent Backpropagation	74	88.08	76
12	Sequential Order Incremental Training with Learning Functions	67	66.23	72

نلاحظ من الجداول الأربعة السابقة [a,b,c,d (5-5)] أن أفضل الخوارزميات التي تعطي أعلى دقة تصنيف بالنسبة لمجموعة البيانات الثالثة هي الخوارزميات التالية بالترتيب حسب الجدول (a5-5) مع تركيب بنية الشبكة العصبونية (عدد العصبونات في كل طبقة حسب الترتيب من اليمين إلى اليسار: طبقة الخرج - الطبقة المخفية 2- الطبقة المخفية 1 - طبقة الدخل) ودقة التصنيف:

- (1) خوارزمية Resilient Back-propagation (RP): وفق بنية [25-23-17-4] ودقة تصنيف 90%.
- (2) خوارزمية Scaled Conjugate Gradient (SCG): وفق بنية [25-48-11-4] ودقة تصنيف 88%.
- (3) خوارزمية Bayesian Regularization (BR): وفق بنية [25-8-11-4] ودقة تصنيف 86%.

4) خوارزمية Levenberg Marquardt (LM): وفق بنية [4-3-2-25] ودقة تصنيف 84%.

حيث سجلت هذه الخوارزميات دقة تصنيف أفضل من بقية الخوارزميات بقيمة تتراوح من 2% إلى 14% (تم حساب هذا المجال عن طريق مقارنة أعلى دقة بين الخوارزميات الأربعة مع أعلى دقة من بقية الخوارزميات ومقارنة أدنى دقة من الخوارزميات الأربعة مع أدنى دقة من بقية الخوارزميات) وبزمن تدريب أقصر من بقية الخوارزميات بقيمة تتراوح من 2 إلى 16 أضعاف الزمن اللازم لتقارب الخوارزمية على مجموعة البيانات الثالثة.


بمقارنة نتائج التجربة الثالثة وفق الجداول [5-5] a,b,c,d مع نتائج الجداول في التجربة الأولى وفق الجداول [5-2] a,b,c,d نلاحظ انخفاض أداء الشبكة عند الفحص والتدريب في كل خوارزميات التدريب بقيمة تتراوح بين 1% إلى 3% باستثناء خوارزمية Resilient Back-propagation التي تحسن فيها أداء تصنيف الشبكة في التجربة الثالثة بقيمة 2.3%. نستنتج أن إضافة مطال تحويل فورييه لكل من مخططي (تدفق-حجم) و(حجم-زمن) لبيانات دخل الشبكة العصبونية في التجربة الثالثة لم يؤثر سلباً على أداء الشبكة بشكل كبير كما أنه لم يؤثر إيجاباً أيضاً.

5-4 التجربة الرابعة: تقييم دقة تصنيف برنامج جهاز وظائف الرئة

بعد استحصال 276 عينة تم تصنيفها من قبل برنامج جهاز وظائف الرئة PFT قمنا بمقارنة نتائج التصنيف الآلي لبرنامج الجهاز مع قرار الأطباء الخبراء في هذا المجال لنفس العينات وحساب معايير دقة التصنيف.

أعطى الجهاز ناتج تصنيف لهذه العينات (276) على الشكل التالي: 118 حالة سليمة و 68 حالة مرض ساد و 64 حالة مرض قصور و 26 حالة مرض ممزوج. أما نتائج تصنيف الطبيب فكانت على الشكل التالي: 111 حالة سليمة و 83 حالة مرض ساد و 47 حالة مرض قصور و 35 حالة مرض ممزوج. يوضح الشكل (5-10) مقارنة نتائج برنامج الجهاز مع رأي الطبيب المختص بالنسبة لكل حالة من حالات التصنيف الأربعة:

تقييم أداء تصنيف برنامج جهاز وظائف الرئة PFT



الشكل (5-10) تقييم نظام تصنيف برنامج التشخيص الآلي لجهاز وظائف الرئة يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات السلبية والإيجابية ومساحة المحصورة تحت منحنى ROC لكل صنف من الأصناف الأربعة مع متوسط الأداء على اليمين

باستخدام المعايير الإحصائية لتقييم أداء التصنيف الموضحة في المعادلة (4-14) لحساب الدقة و(4-15) لحساب الحساسية و(4-16) لحساب النوعية و(4-21) لحساب قيمة AUC و(4-18) لحساب قيمة NPV و(4-17) لحساب قيمة PPV نجد أن برنامج الجهاز قد حقق القيم المتوسطة (للأصناف الأربعة) التالية: دقة تصنيف 0.911 وحساسية تصنيف 0.8 ونوعية تصنيف 0.94 ومساحة السطح تحت منحنى ROC هي 0.87 وقيمة التنبؤ السالبة 0.85 والموجبة 0.92 على الترتيب. تجدر الإشارة إلى أن هذه القيم توضح مدى تطابق رأي برنامج الجهاز مع رأي الطبيب المختص.

5-6 تقييم دقة تصنيف تجارب الشبكة العصبونية (على مجموعات الفحص)

تم اختيار الخوارزميات الأربعة التي أعطت نتائج أفضل من بقية الخوارزميات كما ورد في الفقرات السابقة بالإضافة إلى اختيار تركيبة الشبكة بتحديد عدد عصبونات الطبقات المخفية التي تتوافق مع أفضل دقة تصنيف مع اعتماد تسوية بيانات دخل $[-1, +1]$ وطبقتين مخفيتين التي أعطت أفضل نتائج


كما ورد في التجارب الثلاثة السابقة. قمنا بإعادة عملية التدريب عدة مرات - 100 مرة - لكل خوارزمية مع تثبيت كل متغيرات الخوارزمية وإسناد أوزان ابتدائية عشوائية لكل من طبقة الدخل والطبقات المخفية وذلك للحصول على أفضل النتائج (أي أفضل قيم للأوزان والانزياحات التي تزيد من دقة تصنيف الشبكة العصبونية بالنسبة لكل من عينات التدريب 60% والفحص 20% من عدد العينات الكلي في كل مجموعة من المجموعات الثلاث). بعد ذلك تم فحص الشبكة العصبونية المصممة على عينات الفحص في كل مجموعة من مجموعات البيانات الثلاث كما سنرى في الفقرات التالية.

5-6-1 تقييم نتائج الشبكة العصبونية المصممة MLP على عينات الفحص للمجموعة الأولى

تمكنا بعد تقييم نتائج التجارب السابقة المعروضة في الجداول [a,b,c,d (2-5)] من تحديد متغيرات الشبكة العصبونية الأنسب من حيث أسلوب إعادة التسوية وعدد الطبقات المخفية وعدد العصبونات في كل طبقة مخفية بالإضافة إلى أفضل الخوارزميات التي حققت أفضل دقة تصنيف للعينات - يلخص الجدول (5-6) هذه النتائج - قمنا بعد ذلك بإعادة عملية التدريب عدة مرات - 100 مرة - لكل خوارزمية مع تثبيت كل متغيرات الخوارزمية وإسناد أوزان ابتدائية عشوائية للحصول على أفضل النتائج. تم تحليل هذه النتائج وإحصاء العينات التي تم تصنيفها بشكل صحيح وغير صحيح بالمقارنة مع رأي الطبيب المختص وحساب المعايير الإحصائية لأداء التصنيف بالنسبة لمجموعة الفحص وعرضها وفق الشكل (5-11).

الجدول (5-6) إعدادات الشبكة العصبونية المصممة حسب الخوارزميات الأربعة من أجل مجموعة البيانات الأولى

الخوارزمية	التسوية	توابع التفعيل	عدد العصبونات	LR
Levenberg Marquardt (LM)	[-1,+1]	قطعية Tangent	23-5-17-4	0.001
Bayesian Regularization (BR)	[-1,+1]	قطعية Tangent	23-6-28-4	0.005
Scaled Conjugate Gradient (SCG)	[-1,+1]	قطعية Tangent	23-34-27-4	0.001
Resilient Backpropagation (RP)	[-1,+1]	قطعية Tangent	23-33-29-4	0.07



نلاحظ من الشكل (5-11) أن الخوارزميات الأربعة قد تفوقت على برنامج الجهاز من حيث معايير الدقة (أكبر من 90%) والنوعية (أكبر من 95%) وقيمة PPV (أكبر من 94%) وقيمة AUC (أكبر من 90%) وقيمة الخطأ MSE (أصغر من 0.07) فكانت معايير برنامج الجهاز أقل من هذه القيم كما هو موضح بالتفصيل في الجدول (6-1). تفوقت الخوارزمية LM على برنامج الجهاز من حيث الحساسية أيضاً (أكبر من 80%) وقيمة NPV (أكبر من 85%) أما بقية الخوارزميات لم تتفوق على برنامج الجهاز في هذه المعايير. أي أن الخوارزمية LM قد تفوقت على برنامج الجهاز في كافة المعايير. يبين الملحق الثالث النتائج التفصيلية لأداء الشبكة العصبونية المصممة MLP في التصنيف الآلي لكل صنف من الأصناف الأربعة (سليم Normal, مرض ساد Obstructive, مرض قصور Restrictive, مرض مختلط Mixed).


5-6-2 تقييم نتائج الشبكة العصبونية المصممة MLP على عينات الفحص للمجموعة الثانية

تمكنا بعد تقييم نتائج التجارب السابقة المعروضة في الجداول [a,b,c,d (3-5)] من تحديد متغيرات الشبكة العصبونية الأنسب حسب الجدول (5-7) وإعادة عملية التدريب عدة مرات - 100 مرة - لكل

خوارزمية مع تثبيت كل متغيرات الخوارزمية وإسناد أوزان ابتدائية عشوائية للحصول على أفضل النتائج. تم تحليل هذه النتائج وإحصاء العينات التي تم تصنيفها بشكل صحيح وغير صحيح بالمقارنة مع رأي الطبيب المختص وحساب المعايير الإحصائية لأداء التصنيف بالنسبة لمجموعة الفحص في المجموعة الثانية وعرضها وفق الشكل (5-12) بالإضافة لمقارنتها مع نتائج أداء برنامج الجهاز PFT.

الجدول (5-7) إعدادات الشبكة العصبونية المصممة حسب الخوارزميات الأربعة من أجل مجموعة البيانات الثانية

الخوارزمية	التسوية	توابع التفعيل	عدد العصبونات	LR
Levenberg Marquardt (LM)	$[-1, +1]$	قطعية Tangent	13-7-24-4	0.001
Bayesian Regularization (BR)	$[-1, +1]$	قطعية Tangent	13-7-25-4	0.005
Scaled Conjugate Gradient (SCG)	$[-1, +1]$	قطعية Tangent	13-36-19-4	0.001
Resilient Backpropagation (RP)	$[-1, +1]$	قطعية Tangent	13-19-16-4	0.07



الشكل (5-12) نتائج أداء تصنيف الشبكة العصبونية بالخوارزميات الأربعة على مجموعة البيانات الثانية (مجموعة الفحص)، يتضمن معايير الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

نلاحظ من الشكل (5-12) أن الخوارزميات الأربعة قد تفوقت على برنامج الجهاز من حيث معايير قيمة AUC (أكبر من 90%) وقيمة الخطأ MSE (أصغر من 0.86) فكانت معايير برنامج الجهاز أقل من هذه القيم كما هو موضح بالتفصيل في الجدول (6-1). أما بقية المعايير للخوارزميات فكانت كالتالي: الدقة


(أكبر من 90%) والحساسية ضمن المجال [85%, 75%] والنوعية ضمن المجال [95%, 90%] وقيمة NPV ضمن المجال [85%, 80%] وقيمة PPV ضمن المجال [95%, 90%]. يبين الملحق الثالث النتائج التفصيلية لأداء الشبكة العصبونية المصممة MLP في التصنيف الآلي لكل صنف من الأصناف الأربعة (سليم Normal, مرض ساد Obstructive, مرض قصور Restrictive, مرض مختلط Mixed).

5-6-3 تقييم نتائج الشبكة العصبونية MLP على عينات الفحص للمجموعة الثالثة:

تمكنا بعد تقييم نتائج التجارب السابقة المعروضة في الجداول [a,b,c,d (5-5)] من تحديد متغيرات الشبكة العصبونية الأنسب حسب الجدول (5-8) وإعادة عملية التدريب عدة مرات - 100 مرة - لكل خوارزمية مع تثبيت كل متغيرات الخوارزمية وإسناد أوزان ابتدائية عشوائية للحصول على أفضل النتائج. تم تحليل هذه النتائج وإحصاء العينات التي تم تصنيفها بشكل صحيح وغير صحيح بالمقارنة مع رأي الطبيب المختص وحساب المعايير الإحصائية لأداء التصنيف بالنسبة لمجموعة الفحص في المجموعة الثالثة وعرضها وفق الشكل (5-13) بالإضافة لمقارنتها مع نتائج أداء برنامج الجهاز PFT.

الجدول (5-8) إعدادات الشبكة العصبونية المصممة حسب الخوارزميات الأربعة من أجل مجموعة البيانات الثالثة

LR	عدد العصبونات	توابع التفعيل	التسوية	الخوارزمية
0.001	25-2-3-4	Tangent	[-1,+1]	Levenberg Marquardt (LM)
0.005	25-8-11-4	Tangent	[-1,+1]	Bayesian Regularization (BR)
0.001	25-48-11-4	Tangent	[-1,+1]	Scaled Conjugate Gradient (SCG)
0.07	25-23-17-4	Tangent	[-1,+1]	Resilient Backpropagation (RP)



الشكل (5-13) نتائج أداء تصنيف الشبكة العصبونية بالخوارزميات الأربعة على مجموعة البيانات الثانية (مجموعة الفحص)، يتضمن معايير الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC


نلاحظ من الشكل (5-13) أن الخوارزميات الأربعة قد تفوقت على برنامج الجهاز من حيث معايير الدقة (أكبر من 90%) والنوعية (أكبر من 95%) وقيمة PPV (أكبر من 90%) وقيمة AUC (أكبر من 90%) وقيمة الخطأ MSE (أصغر من 0.48) فكانت معايير برنامج الجهاز أقل من هذه القيم كما هو موضح بالتفصيل في الجدول (6-1). أما بقية المعايير للخوارزميات فكانت كالتالي: الحساسية ضمن المجال [80%, 60%] وقيمة NPV ضمن المجال [90%, 60%]. يبين الملحق الثالث النتائج التفصيلية لأداء الشبكة العصبونية المصممة MLP في التصنيف الآلي لكل صنف من الأصناف الأربعة (سليم Normal, مرض ساد Obstructive, مرض قصور Restrictive, مرض مختلط Mixed).



5-7 مثال تدريبي لأفضل النتائج للشبكات العصبونية

نعرض مثال لتدريب الشبكة العصبونية المصممة نوع MLP باستخدام خوارزمية Levenberg Marquardt (LM) على مجموعة بيانات الدخل الأولى وفق الإعدادات والنتائج المعروضة في الجدول (5-9) والشكل (5-14) الذي يعرض مخططات ال ROC ومخطط الخطأ لمجموعات التدريب والتوثيق والفحص:

الجدول (9-5) إعدادات الشبكة العصبونية في المثال التدريبي

Neural Network (MLP) Configurations (Example-1)			
Layer	Neurons Count	Activation Function	Normalization
Input	23	Hyperbolic Tangent	[-1,+1]
Hidden 1	5	Hyperbolic Tangent	[-1,+1]
Hidden 2	17	Hyperbolic Tangent	[-1,+1]
Output	4	Hyperbolic Tangent	[-1,+1]
Error	Epoch	Learning Rate	Training Algorithm
0.0491	17	0.001	Levenberg Marquardt
Dim*Samples	Training	Validation	Testing
23*201	121	40	40
Accuracy	Sensitivity	Specificity	
0.950	0.836	0.979	





الشكل (b14-5) يوضح منحنيات تابع الخطأ MSE لكل من مجموعة التدريب بالأزرق والتوثيق بالأخضر والفحص بالأحمر مع تغير عصور التدريب epochs

الشكل (a14-5) يوضح مخططات ROC المتعلقة بكل من مجموعة التدريب والتوثيق والفحص والمجموعة الكلية، كل لون من الألوان في الشكل يمثل منحنى ROC الخاص بكل صنف من أصناف الأمراض الأربعة التي يجري تصنيفها

الشكل (14-5) أحد أفضل النتائج التي حصلنا عليها أثناء التدريب باعدادات الجدول (9-5)

يوضح الملحق الثاني نتائج بعض الحالات التدريبية.

8-5 تقنية التوقف المبكر للتدريب Early Stopping Technique

تم بناء الشبكة العصبونية وتجهيزها بالإعدادات كما في الجدول (5-10):

الجدول (5-10) إعدادات الشبكة العصبونية توضح تقنية التوقف المبكر

Neural Network (MLP) Configurations			
Layer	Neurons Count	Activation Function	Normalization
Input	23	Hyperbolic Tangent	[-1,+1]
Hidden 1	6	Hyperbolic Tangent	[-1,+1]
Hidden 2	28	Hyperbolic Tangent	[-1,+1]
Output	4	Hyperbolic Tangent	[-1,+1]
Error	Epoch	Learning Rate	Training Algorithm
0.0513	14	0.005	Bayesian Regularization
Dim*Samples	Training	Validation	Testing
23*201	121	40	40
Accuracy	Sensitivity	Specificity	
0.940	0.686	0.968	


وكان منحنى الخطأ MSE بدلالة عصور التدريب Epochs لكل من مجموعة التدريب والتوثيق والفحص كما هو معروض من الشكل (5-15) حيث يمثل الخط الأزرق خطأ مجموعة التدريب والأخضر خطأ مجموعة التوثيق والأحمر خطأ مجموعة الفحص.

يمكن أن نحسب قيمة MSE من قيمة SSE حسب المعادلة (4-20) حيث يمثل N عدد العينات التدريب وهو 60% من عدد العينات الكلي (380 عينة) ويساوي 228 عينة وبالتالي يمكن حساب خطأ التدريب بتعويض هذه القيم في المعادلة (4-20) كما يلي:

$$MSE = \frac{SSE}{N} = \frac{11.78}{228} = 0.0513$$

أما خطأ التعميم (مجموعة الفحص 20% أي 76 عينة) فقد تم حسابه وفق المعادلة (5-14) كما يلي:

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{NP} = \frac{\sum_{j=0}^4 \sum_{i=0}^{76} (d_{ij} - y_{ij})^2}{76 \times 4} \approx 0.0536$$



الشكل (5-15) مزايا تقنية التوقف المبكر عند التدريب للحفاظ على قدرة الشبكة على التعميم

الخلاصة:

استعرضنا في هذا الفصل الخطوات الأساسية المتبعة في هذه الدراسة لإنجاز التجارب العملية للشبكة العصبونية المصممة وبرنامج جهاز وظائف الرئة PFT وتحصيل النتائج ومقارنتها بين بعضها. شرح هذا الفصل الخطوات والتجارب التي تم تنفيذها على مجموعات التدريب لمجموعات البيانات الثلاثة من أجل الوصول إلى التصميم الأمثل للشبكة العصبونية من أجل معالجة الهدف من هذا البحث (التشخيص الآلي لأمراض جهاز التنفس باستخدام الشبكات العصبونية). شملت هذه التجارب نوع الشبكة وأسلوب تسوية بيانات الدخل وتوابع التفعيل وعدد عصبونات الطبقات المخفية وخوارزمية التدريب وتقنية التوقف المبكر وإضافة قياسات جديدة لبيانات الدخل (مطال تحويل فورييه). قمنا أيضاً في هذا الفصل بتعليل نتائج الشبكة العصبونية الأولية ومقارنتها بين بعضها وتحديد الأفضل منها بالإضافة إلى مقارنتها مع برنامج الجهاز. سيتم في الفصل اللاحق فحص هذه النتائج وعرض النتائج النهائية وفق المعاملات الإحصائية المطروحة في البحث والاستنتاجات وتعليل أسبابها بالإضافة إلى مقارنة النتائج النهائية مع نتائج الدراسات السابقة.

الفصل السادس

تحليل ومناقشة النتائج

6-1 تصميم الشبكة العصبونية MLP وتحديد معاملاتها المثلى

6-1-1 نوع الشبكة العصبونية المصممة

تم اختيار نوع الشبكة العصبونية المناسب لهذه الدراسة بناءً على العينات التي حصلنا عليها من جهاز وظائف الرئة والتي هي ثنائيات (دخل - هدف)، أي أننا نعرف مسبقاً هدف الشبكة العصبونية المراد الوصول إليه وهو التشخيص الطبي حسب رأي الطبيب المختص. لهذا السبب اخترنا نوع التعليم الموجه ولم نتعرض للتعليم غير الموجه كما تم توضيحه مسبقاً في الفقرة [4-5]. كما أننا لم نستخدم شبكات من النوع Elman أو نوع التغذية الخلفية أو من النوع Hopfield لعدم حاجة بيانات الدخل في بحثنا إلى وجود تغذية راجعة عكسية بين الخرج والدخل. حققت الشبكة العصبونية من نوع التغذية الأمامية MLP متطلبات دراستنا من حيث التوافق مع نمط الدخل (دخل-هدف) وقدرتها على التعلم من إدخال الأمثلة والتجريب وقدرتها على تعميم عملية التعلم بالنسبة للعينات التي لم تتدرب عليها من قبل.

6-1-2 أسلوب تسوية بيانات الدخل

تمت معالجة كل مجموعة بيانات دخل من المجموعات الثلاث قبل إدخالها للشبكة العصبونية باستخدام طريقتين مختلفتين لتسوية البيانات هما $[-1, +1]$ والتسوية $[0, +1]$. أشارت نتائج حساب دقة التصنيف في التجربة الأولى على بيانات الدخل الأولى (23p201) من أجل كل أنواع الخوارزميات المقترحة أن تسوية البيانات $[-1, +1]$ هي بشكل عام أفضل من التسوية $[0, +1]$ بقيمة تصل إلى 25% في المجموعة الأولى (الخوارزمية رقم 12 "Sequential Order Incremental Training" في الجدولين (c2-5) و (d2-5)). حصلنا أيضاً على نفس النتيجة وبتحسن قدره 10% على مجموعة بيانات الدخل الثانية (13p380) في التجربة الثانية (الخوارزمية رقم 11 "Gradient Descent Back-propagation" في الجدولين (c3-5) و (d3-5))، وكذلك الأمر بالنسبة لمجموعة بيانات الدخل الثالثة (25p201) في التجربة الثالثة حيث حصلنا على نتائج تصنيف من استخدام تسوية $[-1, +1]$ أفضل من تلك باستخدام تسوية $[0, +1]$ وبلغ مقدار التحسن 10% (الخوارزمية رقم 2 "Bayesian Regularization" في الجدولين (a5-5) و (b5-5)).

6-1-3 نوع توابع التفعيل

تستخدم عادة توابع التفعيل القطعية في التسوية $[-1, +1]$ بينما تستخدم توابع التفعيل اللوغاريتمية في التسوية $[0, +1]$. أشارت التجارب في الفقرة السابقة أن استخدام تسوية بيانات الدخل $[-1, +1]$ هي الأفضل لذلك لزم أن نستخدم توابع تفعيل قطعية Hyperbolic Tangent لضمان تحصيل أفضل دقة تصنيف لنموذج الشبكة العصبونية. أشارت الجداول $[a, b, c, d (2-5)]$ والجداول $[a, b, c, d (3-5)]$ والجداول $[a, b, c, d (5-5)]$ أن دقة التصنيف في الشبكة العصبونية MLP عند استخدام أسلوب تسوية $[-1, +1]$ مع توابع تفعيل قطعية أفضل منها عند استخدام أسلوب تسوية $[0, +1]$ مع توابع تفعيل لوغاريتمية بقيمة تصل إلى 25% في المجموعة الأولى و 10% في المجموعة الثانية والثالثة كما ذكرنا في الفقرة السابقة.

6-1-4 عدد الطبقات المخفية وعدد العصبونات فيها

لتحديد عدد عصبونات الطبقة المخفية سواء الأحادية أو الثنائية تم الاعتماد على المعادلات (4-11) و (4-12) و (4-13) [12], لتحديد عدد مبدئي هو منتصف المجال الذي سوف يتم فيه تغيير عدد عصبونات الطبقة المخفية (أحادية أم ثنائية), فكان مجال تغيير عدد العصبونات في الطبقة المخفية الأحادية هو $[2, 100]$ وفي الطبقة المخفية الثنائية هو $[2, 30]$ في الطبقة المخفية الأولى و $[2, 50]$ في الطبقة المخفية الثانية. تم تغيير عدد العصبونات باستمرار وفق المجال المحدد للحصول على العدد الأفضل الذي ينسجم مع أفضل دقة تصنيف للشبكة العصبونية مع تغيير خوارزمية التدريب كما هو مبين في الجداول $[a, b, c, d (2-5)]$ والجداول $[a, b, c, d (3-5)]$ والجداول $[a, b, c, d (5-5)]$ لمجموعات البيانات الثلاثة في التجارب الثلاثة. وقد تبين أنه أي تغيير في متغيرات بنية الشبكة العصبونية يسبب تغير كبير في العدد المناسب لأفضل دقة تصنيف – وطبعاً ليس هنالك قاعدة ثابتة لتعيين هذا العدد إلا من خلال التجريب والتدريب – و لكن يمكن أن نتبين من الجداول المذكورة مسبقاً على مجموعات بيانات الدخل الثلاث أن دقة التصنيف في الشبكة العصبونية ثنائية الطبقة المخفية أفضل منها في حالة الطبقة الأحادية بقيمة تصل إلى 19% في مجموعة بيانات الدخل الأولى (الخوارزمية رقم 12 “Sequential Order Incremental Training” في الجدولين $(b2-5)$ و $(d2-5)$),

وكذلك حصلنا في المجموعة الثانية على تحسن في الطبقة الثنائية بقيمة تصل إلى 6% (الخوارزمية رقم 3 "Scaled Conjugate Gradient" في الجدولين (a3-5) و (c3-5)). وجدنا نفس النتيجة في المجموعة الثالثة وبتحسن في الطبقة الثنائية يصل إلى 16% (الخوارزمية رقم 8 "Fletcher-Powell Conjugate Gradient" في الجدولين (a5-5) و (c5-5)). يمكن أن يكون ذلك بسبب أن الربط بين هذه البيانات المعقدة صعب بعض الشيء ويقتضي وجود تركيبة شبكة عصبونية أكثر تعقيداً، ولكننا نعلم أن زيادة عدد الطبقات يمكن أن يزيد من زمن المعالجة (زمن التدريب اللازم لتقارب الخوارزمية) بسبب زيادة التعقيد الحسابي للمسألة وقد زاد زمن التدريب في الشبكة العصبونية ذات الطبقة المخفية الثنائية بنسبة تصل إلى 50 ضعف عنها في حالة الطبقة المخفية الأحادية.

5-1-6 نوع خوارزمية التدريب

تم التعامل مع عدد من خوارزميات التدريب للشبكة العصبونية التي يركز مبدؤها على التغيير في أوزان وإنزياحات كل من عصبونات الطبقات بهدف تصغير الفارق الحاصل بين النتائج الفعلية للشبكة العصبونية وقيم الهدف المراد الوصول إليها خلال تنفيذ عملية التدريب. تم إجراء التجارب العملية على 12 خوارزمية تدريب مختلفة من حيث مبدأ معدل التعلم ومعايير حساب الخطأ وخطوة الزيادة والنقصان للأوزان والانزياحات بعد كل عصر تدريب كما هو معروض في الجداول [a, b, c, d (2-5)] والجداول [a, b, c, d (3-5)] والجداول [a, b, c, d (5-5)]. أشارت النتائج في هذه الجداول إلى وجود أربعة خوارزميات تعطي أفضل النتائج من حيث دقة التصنيف، حيث حققت هذه الخوارزميات الأربعة تحسن في دقة التصنيف تتراوح بين [2%, 32%] في المجموعة الأولى وبقيمة تصل إلى 5% في المجموعة الثانية وبقيمة تصل إلى 14% في المجموعة الثالثة. هذه الخوارزميات الأربعة هي:

- 1- خوارزمية (Levenberg Marquardt (LM).
- 2- خوارزمية Scaled Conjugate Gradient Back-propagation (SCG).
- 3- خوارزمية Resilient Back-propagation (RP).
- 4- خوارزمية Bayesian Regularization Back-propagation (BR).

من المهم أن نشير أيضاً إلى أن بقية الخوارزميات المستخدمة كما هو معروض في الجداول (2-5) و(3-5) و(5-5) أعطت نتائج جيدة أي دقة تصنيف تصل إلى 86% مثل الخوارزمية ذات الأرقام 6 و7 و8 و9 و12 ولكنها كانت تستغرق وقت أكبر بحوالي 6 إلى 9 أضعاف الزمن المستغرق في الخوارزميات الأربعة السابقة، أما بقية الخوارزميات ذات الأرقام 5 و10 و11 فقد كانت ذات نتائج جيدة أي دقة تصنيف تصل إلى 81% ولكنها تستغرق وقت أطول بحوالي 16 ضعف من سابقتها. نستنتج أن الخوارزميات الأربعة هي الأفضل أيضاً من حيث الزمن اللازم للتدريب (تقارب الخوارزمية).

6-1-6 تغيير الأوزان والانزياحات الابتدائية

استخدمت الاستنتاجات في الفقرات السابقة من أجل إعادة تدريب الشبكة العصبونية المصممة ودراسة أثر تغيير الأوزان والانزياحات الابتدائية لكافة الطبقات بشكل تكراري للحصول على أفضل النتائج. تبين أنه يمكن مع اختيار الأوزان والانزياحات البدائية المناسب أن نحسن من دقة التصنيف في كل من مجموعتي التدريب والفحص وهذا ما يرفع من كفاءة تصنيف الشبكة (دقة - حساسية - نوعية - MSE - AUC) كما هو موضح بمقارنة النتائج الأولية في الجداول [a, b, c, d (2-5)] والجداول [a, b, c, d (3-5)] والجداول [a, b, c, d (5-5)] مع النتائج النهائية في الجدول (1-6). على سبيل المثال، تحسنت دقة التصنيف بالنسبة 10% حيث كانت دقة تصنيف (فحص) في التجربة الأولى لخوارزمية Levenberg Marquardt رقم (1) في الجدول (2-5a) من القيمة 86% إلى القيمة 95% في الجدول (1-6). ذلك يمكن أن يعزى إلى أن تحديد الأوزان والانزياحات الابتدائية المناسبة يمكن أن يساعد خوارزمية التدريب بشكل كبير في الوصول إلى النهاية الصغرى المطلوبة Global Minima وتحقيق تقارب الخوارزمية بشكل سهل وسريع.

7-1-6 استخدام تقنية التوقف المبكر خلال عملية التدريب Early Stopping

نلاحظ من الشكل (5-15) أن أهم ميزة من ميزات استخدام تقنية التوقف المبكر هو أن عدد العصور اللازمة للتدريب أغلب الأحيان يكون قليل ويمكن أن يخفض ذلك من قدرة الشبكة على إنقاص الخطأ MSE. لكن هذا طبعاً يكون بهدف كسب ميزة أهم وهي قدرة الشبكة على التعميم واتخاذ القرار من أجل

عينات لم تتدرب عليها من قبل، وبذلك لا تسلك الشبكة العصبونية سلوك الذاكرة. نلاحظ من الشكل أن الشبكة قد أوقفت عملية التدريب عند العصر 14 على الرغم من استمرار تناقص خطأ التدريب (باللون الأزرق) وذلك لأن خطأ مجموعة التوثيق بدأ بالزيادة وهذا السلوك سوف ينقص من تعميم الشبكة وبالتالي زيادة الخطأ في مجموعة الفحص.

نلاحظ من الشكل (5-15) أن النقطة عند قيمة مجموع مربع الأخطاء $SSE=11.78$ والعصر $Epoch=14$ تمثل أقل خطأ تعميم (مجموعة التوثيق) يمكن أن يحققه الشبكة خلال عملية التدريب بعدها يبدأ خطأ التعميم بالزيادة ليثبت عند قيمة ثابتة، بينما يستمر خطأ التدريب بالنقصان. وبالنتيجة تم حساب خطأ التدريب من قيمة MSE لمجموعة التدريب (60%) حسب المعادلة (4-19) بينما يُحسب خطأ التعميم من قيمة MSE لمجموعة الفحص (20%) بنفس المعادلة (4-19).

بينت الحسابات التي تم إجراؤها في الفقرة [5-8]: أن قيمة خطأ التدريب مقاربة لقيمة خطأ التعميم بفضل استخدام تقنية التوقف المبكر التي تحافظ على قدرة الشبكة على التعميم وتمنع زيادة خطأ التعميم.

6-2 نتائج الشبكة العصبونية المصممة باستخدام الخوارزميات الأربعة على مجموعات البيانات الثلاث بالمقارنة مع أداء برنامج جهاز وظائف الرئة PFT

يلخص الجدول (6-1) النتائج التي حصلنا عليها من فحص الشبكة العصبونية المصممة والتي عرضنا نتائج أداء التصنيف فيها على مجموعات البيانات الثلاث في الأشكال (5-11) و (5-12) و (5-13) بالإضافة إلى نتائج أداء برنامج الجهاز (التي هي مقدار التطابق بين رأي الجهاز مع رأي الطبيب المختص) التي تم عرضها في الشكل (5-10). يشير الصف الأول إلى نتائج التصنيف الآلي لبرنامج جهاز PFT بالمقارنة مع رأي الطبيب المختص حسب المعايير الاحصائية السبعة التي تم شرحها في الفصل الرابع وهي الدقة Accuracy والحساسية Sensitivity والنوعية Specificity والقيمة التنبؤية السالبة NPV والموجبة PPV ومساحة السطح AUC المحصور تحت ROC و الخطأ MSE وعصور التدريب Epoch ومعدل التعلم LR على الترتيب، بينما تشير بقية الصفوف إلى نتائج أداء تصنيف الشبكة العصبونية MLP باستخدام الخوارزميات الأربعة على مجموعات بيانات الدخل الثلاث.

الجدول (1-6) مقارنة نتائج تصنيف نماذج الشبكات العصبونية المختلفة مع برنامج جهاز PFT


	متوسط قيم معايير أداء التصنيف (للأصناف الأربعة)								
	Accuracy	Sensitivity	Specificity	NPV	PPV	AUC	MSE	Epoch	LR
برنامج PFT	0.911	0.800	0.940	0.852	0.919	0.870	0.163	NA	NA
23p201LM	0.950	0.836	0.979	0.887	0.951	0.957	0.033	17	0.001
23p201BR	0.940	0.686	0.968	0.698	0.948	0.958	0.058	14	0.005
23p201RP	0.952	0.672	0.980	0.891	0.953	0.907	0.07	25	0.07
23p201SCG	0.948	0.678	0.984	0.809	0.943	0.958	0.057	27	0.001
13p380LM	0.922	0.843	0.942	0.843	0.933	0.938	0.076	9	0.001
13p380BR	0.903	0.775	0.930	0.807	0.919	0.923	0.07	12	0.005
13p380RP	0.913	0.800	0.948	0.844	0.912	0.938	0.086	41	0.07
13p380SCG	0.905	0.799	0.929	0.812	0.916	0.929	0.076	67	0.001
25p201LM	0.948	0.760	0.961	0.790	0.961	0.956	0.048	8	0.001
25p201BR	0.948	0.762	0.977	0.795	0.948	0.961	0.044	6	0.005
25p201RP	0.945	0.670	0.975	0.880	0.946	0.936	0.033	31	0.07
25p201SCG	0.935	0.618	0.970	0.605	0.938	0.831	0.037	39	0.001

نستنتج من الجدول (1-6) أن الخوارزمية LM قد حققت أفضل نتائج تصنيف بين الخوارزميات في المجموعتين الأولى والثانية وفق كل المعايير الإحصائية السبعة، بينما كانت الخوارزمية RP هي الأفضل في أداء التصنيف بين الخوارزميات الأربعة على المجموعة الثالثة. تعرض الفقرات [1-6-5]، [2-6-5]، [3-6-5] مناقشة أكثر تفصيلاً لنتائج الجدول (1-6).

3-6 نتائج الشبكة العصبونية المصممة على مجموعة البيانات الأولى باستخدام منحنى ROC

تم تطبيق الشبكة العصبونية المصممة باستخدام الخوارزميات الأربعة على مجموعة البيانات الأولى فقط، تم بعد ذلك رسم منحنيات ROC وحساب قيمة AUC للنتائج التي حصلنا عليها في الفقرة [1-6-5] ومقارنتها مع بعضها ومع تلك النتائج التي حصلنا عليها من برنامج الجهاز في الفقرة [4-5-5]، ويوضح الشكل (1-6) منحنيات ROC الناتجة. يشير الشكل إلى أن قيمة المساحة تحت منحنى ROC (التي يرمز لها بالرمز AUC) قد سجلت قيمة قدرها 0.87 لبرنامج الجهاز. يشير الشكل أيضاً إلى أن


الخوارزميات الأربعة قد أعطت قيم AUC أفضل من تلك في برنامج الجهاز حيث بلغت قيم قدرها 0.957, 0.958, 0.907, 0.958 بالنسبة لخوارزميات LM, BR, RP, SCG على الترتيب.



الشكل (6-1) منحنيات الـ ROC لخوارزميات التدريب الأربعة LM, BR, RP, SCG المستخدمة من أجل مجموعة العينات الأولى وفق معيار قيم مساحة المنحني المحصور تحت منحنى الـ ROC المميز لعملية التصنيف المتبعة على عينات الفحص

نستنتج أن الخوارزميات LM, BR, RP, SCG هي التي تعطي أفضل النتائج على مجموعة البيانات الأولى، ولكن بالعودة إلى الجدول (1-6) والشكل (5-11) نجد أن الخوارزمية LM هي التي تعطي نتائج أفضل بالنسبة لبقية المعايير الإحصائية كما هو موضح في الفقرة [2-6].

4-6 نتائج الشبكة العصبونية المصممة على مجموعة البيانات الثانية باستخدام منحنى ROC




الشكل (2-6) منحنيات الـ ROC لخوارزميات التدريب الأربعة LM, BR, RP, SCG المستخدمة من أجل مجموعة العينات الثانية وفق معيار قيم مساحة المنحني المحصور تحت منحنى الـ ROC المميز لعملية التصنيف المتبعة على عينات الفحص

تم تطبيق الشبكة العصبونية المصممة باستخدام الخوارزميات الأربعة على مجموعة البيانات الثانية فقط، تم بعد ذلك رسم منحنيات ROC وحساب قيمة AUC للنتائج التي حصلنا عليها في الفقرة [2-6-5] ومقارنتها مع بعضها ومع تلك النتائج التي حصلنا عليها من برنامج الجهاز في الفقرة [4-5-5]، يوضح الشكل (2-6) منحنيات ROC الناتجة. يشير الشكل إلى أن قيمة AUC قد سجلت قيمة قدرها 0.87 لبرنامج الجهاز. يشير الشكل أيضاً إلى أن الخوارزميات الأربعة قد أعطت قيم AUC أفضل من تلك في برنامج الجهاز حيث بلغت قيم قدرها 0.929, 0.938, 0.923, 0.938 بالنسبة لخوارزميات LM, BR, RP, SCG على الترتيب. نستنتج أن الخوارزميات LM, BR, RP, SCG هي التي تعطي أفضل النتائج على مجموعة البيانات الثانية، ولكن بالعودة إلى الجدول (1-6) نجد أن الخوارزمية LM هي التي تعطي نتائج أفضل بالنسبة لبقية المعايير الإحصائية كما هو موضح في الفقرة [2-6].

5-6 نتائج الشبكة العصبونية المصممة على مجموعة البيانات الثالثة باستخدام منحنى ROC


تم تطبيق الشبكة العصبونية المصممة باستخدام الخوارزميات الأربعة على مجموعة البيانات الثالثة فقط، تم بعد ذلك رسم منحنيات ROC وحساب قيمة AUC للنتائج التي حصلنا عليها في الفقرة [3-6-5] ومقارنتها مع بعضها ومع تلك النتائج التي حصلنا عليها من برنامج الجهاز في الفقرة [4-5-5]، يوضح الشكل (3-6) منحنيات ROC الناتجة. يشير الشكل إلى أن قيمة AUC قد سجلت قيمة قدرها 0.87 لبرنامج الجهاز. يشير الشكل أيضاً إلى أن الخوارزميات الأربعة قد أعطت قيم AUC أفضل من تلك في برنامج الجهاز حيث بلغت قيم قدرها 0.831, 0.936, 0.962, 0.956 بالنسبة لخوارزميات LM, BR, RP, SCG على الترتيب. نستنتج أن الخوارزميات LM, BR, RP, SCG هي التي تعطي أفضل النتائج على مجموعة البيانات الثانية، ولكن بالعودة إلى الجدول (1-6) نجد أن الخوارزمتين LM, BR هما اللتين تعطيان نتائج أفضل بالنسبة لبقية المعايير الإحصائية كما هو موضح في الفقرة [2-6].



الشكل (3-6) منحنيات الـ ROC لخوارزميات التدريب الأربعة LM, BR, RP, SCG المستخدمة من أجل مجموعة العينات الثالثة (مطالي تحويل فورييه) وفق معيار قيم مساحة المنحني المحصور تحت منحنى الـ ROC المميز لعملية التصنيف المتبعة على عينات الفحص

6-6 نتائج الشبكة العصبونية المصممة باستخدام الخوارزمية LM على مجموعة البيانات الثلاث باستخدام منحنى ROC

استنتجنا من الفقرات السابقة [3-6] و [4-6] و [5-6] أن الخوارزمية LM هي الأفضل من بين الخوارزميات الأربعة لأنها الخوارزمية الوحيدة التي تعطي معاملات إحصائية أفضل بالمقارنة مع برنامج الجهاز. يوضح الشكل (5-6) مقارنة المعاملات الإحصائية لهذه الخوارزمية مع برنامج الجهاز.



يبين الشكل (4-6) منحنيات ROC لنتائج تطبيق الشبكة العصبونية المصممة باستخدام الخوارزمية LM على مجموعات البيانات الثلاث. يوضح الشكل أن قيمة AUC لبرنامج الجهاز هي 0.87 بينما بلغت قيم AUC لتطبيق الشبكة العصبونية على مجموعة البيانات الأولى والثانية والثالثة نتائج قدرها 0.957, 0.938, 0.956 على الترتيب.


نستنتج من هذا الشكل أن الخوارزمية LM قد أعطت أفضل النتائج على المجموعة الأولى. يمكن أن يُعزى هذا إلى زيادة أبعاد العينة حيث يوجد 23 قياس للعينة الواحدة في المجموعة الأولى بينما هنالك 13 قياس للعينة الواحدة في المجموعة الثانية، وهذا يمكن أن يتيح للشبكة العصبونية زيادة كمية المعلومات المفيدة المدخلة في العينة الواحدة مما يساعد في عملية التدريب. من الجدير بالذكر أن زيادة عدد أبعاد العينة يمكن أن لا يفيد الشبكة العصبونية أحياناً في زيادة كمية المعلومات التي يمكن أن تستفيد منها الشبكة أي تساعد في عملية التدريب، وقد لاحظنا هذه النتيجة في الشبكة العصبونية على مجموعة البيانات الثالثة التي احتوت 25 وأعطت نتائج - كما في الشكل (4-6) والجدول (6-1) - لم تتفوق على تلك التي حصلنا عليها على مجموعة البيانات الأولى (23 قياس). نستنتج أن دراسة ترابط قياسات العينات أمر ضروري لتحديد أهمية الترابط بينها وكمية المعلومات المفيدة.

نستنتج أيضاً أن إضافة قيم مطال تحويل فوربييه لكل من مخططي (تدفق-حجم) و(حجم-زمن) كقياس جديد يُضاف إلى قياسات البيانات لم يؤدي إلى تحسن في النتائج، ولكن لم يؤدي إلى انخفاض النتائج أيضاً. يمكن أن نستنتج أنه يمكن استخدام هذين القياسين الجديدين ولكن نحتاج إلى دراسة أعمق للتأكد فيما إذا كان له أثر في زيادة دقة التشخيص الآلي باستخدام الشبكات العصبونية المصممة.

يمكن أن نلاحظ من الشكل (4-6) أن الخوارزمية LM على مجموعة البيانات الأولى قد حققت تحسین (زيادة) في دقة التشخيص الآلي بالمقارنة مع برنامج الجهاز بمقدار AUC قدره 10%. نستنتج أخيراً أنه يمكن الاستفادة من الشبكة العصبونية المصممة والخوارزمية LM لرفع أداء التشخيص الآلي لجهاز وظائف الرئة PFT.

7-6 مقارنة نتائج أداء تصنيف الشبكة العصبونية المصممة باستخدام الخوارزمية LM على

المجموعة الأولى مع أداء تصنيف برنامج الجهاز



الشكل (5-6) مقارنة أداء تصنيف الشبكة العصبونية المصممة باستخدام الخوارزمية LM على مجموعة البيانات الأولى (مجموعة الفحص) مع أداء برنامج الجهاز، وفق معايير الدقة والحساسية والنوعية والقيمة التنبؤية الإيجابية والسلبية و AUC

يبين الشكل (5-6) مقدار التحسن الذي نحصل عليه من استخدام الشبكة العصبونية المصممة والخوارزمية LM بالمقارنة مع برنامج الجهاز بالنسبة لكافة المعاملات الإحصائية المقترحة في هذه الدراسة. تفوقت هذه الشبكة بمقدار قدره 4% بالنسبة لدقة التصنيف والنوعية وقيمة التنبؤ السالبة وبمقدار قدره 4.5% بالنسبة للحساسية وبمقدار قدره 3.5% بالنسبة لقيمة التنبؤ الموجبة وبمقدار قدره 10% في قيمة AUC وتحسن 5 أضعاف في قيمة الخطأ MSE.

تؤكد هذه النتائج أيضاً على النتيجة التي توصلنا لها في الفقرة 6-6 بأنه يمكن الاستفادة من الشبكة العصبونية المصممة والخوارزمية LM لرفع أداء التشخيص الآلي لجهاز وظائف الرئة.

6-8 مناقشة نتائج هذه الدراسة مع الدراسات المرجعية السابقة

تم تلخيص نتائج هذه الدراسة وفق نموذج جدول مقارنة الدراسات المرجعية الذي ورد ذكره في الفصل الثاني بناءً على عدد مداخل الشبكة العصبونية ونوع الشبكة العصبونية وعدد العينات وعدد الأصناف التي تم تصنيف العينات المستخدمة إليها ومعايير أداء التصنيف التي تتضمن الدقة والحساسية والنوعية كما هو موضح في الجدول (2-6):

الجدول (2-6) ملخص النتائج المستحصلة من هذه الدراسة

#	السنة	العنوان	المؤلفون	عدد القياسات المستخدمة	منهجية الذكاء الصناعي	عينة	النتائج النهائية والمخرجات
#	2013	Using of Computerized Diagnosis in evaluation of Pulmonary Function Test's Results to help in Diagnosis of Respiratory Diseases	This study	23inputs FVC, FEV1, FEV1%, FEF, Height, Weight, Age, Gender, Smoke, PEF, MEF, FFT(flow), FFT(volume), PEFT, FEV2, FEV3	ANN MLP (LM, BR, RP, SCG)	201 + 380 = 581	4 classes: Normal, Obstructive, Restrictive, Mixed. MLP (LM): Acc=95%, Sen=84%, Spec=98% MLP(BR): Acc=94%, Sen=86%, Spec=97% MLP(RB): Acc=95%, Sen=67%, Spec=98% MLP(SCG): Acc=95%, Sen=68%, Spec=98%

نستنتج لدى مقارنة النتائج المعروضة في الجدول (2-6) مع تلك التي ذكرناها في الجدول (2-5) في الفصل الثاني ما يلي:

1. تختلف هذه الدراسة عن الدراسات السابقة ببعض النقاط الأساسية التي قد تؤثر بشكل كبير على النتائج النهائية لعملية التصنيف نذكر منها عدد مداخل الشبكة العصبونية (قياسات جهاز وظائف الرئة) التي كانت في هذه الدراسة 23 قياس (بالإضافة إلى معاملي تحويل فورييه لتصبح 25 قياس)، أما في دراسات أخرى فقد تراوحت بين 3 إلى 18 قياس.

2. اعتمدت هذه الدراسة على الشبكات العصبونية من نوع مستقبلات متعددة الطبقات MLP واستخدام خوارزميات متعددة للتدريب منها LM, بينما اعتمدت بقية الدراسات على عدة أنواع من الشبكات العصبونية منها الشبكات ذاتية التنظيم SOM في [15] وشبكات Elman في [3] وشبكات MLP في [19] وشبكات RBF في [4] و [21] والشبكات الاحتمالية PNN وتكميم شعاع LVQ في [18].
3. تمكنا في هذه الدراسة من تصنيف العينات التي بلغ عددها 581 عينة إلى أربعة أصناف هي الحالات السليمة Normal والحالات المرضية السادة Obstructive والحالات المرضية القاصرة Restrictive والحالات المختلطة Mixed. بينما عملت بعض الدراسات على تصنيف عيناتها إلى صنفين (طبيعي أو ساد) كما في [21] أو ثلاثة أصناف (طبيعي أو ساد أو قصور) كما في [3,4] أو أربعة أصناف كما في دراستنا مثل [19].
4. حققت هذه الدراسة دقة تصنيف 95% وحساسية 83% ونوعية 98%. بينما تمكن [4] من تحقيق دقة تصنيف 96% وحساسية 100% ونوعية 92% من أجل ثلاثة أصناف فقط (طبيعي أو ساد أو قصور), كذلك [23] الذي حقق دقة تصنيف 97%.
5. تفوقت نتائج تقييم أداء عملية التشخيص الآلي لهذه الدراسة على بعض نتائج الدراسات السابقة كما هو موضح في الجدول (2-5) مثل [3] و [21] و [18] من حيث الدقة والحساسية والنوعية.
6. لم تتفوق على الدراسات الأخرى مثل [4] و [23] و [19]. يمكن ان يُعزى ذلك إلى إختلاف عدد الأصناف التي يتم فرز العينات إليها وأختلاف عدد القياسات المستخدمة في الشبكة العصبونية علاوة على إختلاف نوع التعليم أو الشبكة العصبونية أو عدد العينات.
7. لم نستطع مقارنة نتائجنا مع تلك النتائج في المراجع [16, 17, 20, 22] لأنها استخدمت طرق احصائية مختلفة عن تلك التي استخدمناها في تقييم نتائج الشبكة العصبونية المصممة في هذه الدراسة والمستخدم أيضاً في المراجع [3,4,15,19,21,23].

الخلاصة:

استعرضنا في هذا الفصل النتائج النهائية والأسس المتبعة في بناء الشبكة العصبونية المصممة من حيث نوع الشبكة وأساليب تسوية البيانات واختيار توابع التفعيل وتحديد عدد عصبونات الطبقات المخفية والأوزان والانزياحات الابتدائية وتقنية التوقف المبكر. عرضنا أيضاً ملخص النتائج النهائية لتطبيق الشبكة العصبونية بالخوارزميات الأربعة على مجموعات البيانات الثلاث بالإضافة لمخططات ROC ومقارنة نتائجها مع نتائج برنامج الجهاز، ومقارنة النتائج النهائية مع نتائج الدراسات السابقة. سنستعرض في الفصل التالي أهم الاستنتاجات التي حصلنا عليها من إجراء هذه الدراسة والتي تتعلق ببنية الشبكة العصبونية ومقارنتها مع برنامج الجهاز وجدوى استخدامها لرفع أداء التشخيص الآلي في الجهاز.

الفصل السابع

الاستنتاجات

7-1 ملخص العمل في البحث والأهداف المحققة

درسنا في هذا البحث العلمي جهاز وظائف الرئة وما هي أهم القياسات المستخدمة في تشخيص أمراض الرئة والعلاقة فيما بينها التي تساعد الأطباء الخبراء في اتخاذ قرار التشخيص الأولي لأربعة أصناف من الحالات التي تتعلق بالحالة الصحية لجهاز التنفس عند الإنسان وهي: الحالات السليمة والسادة والحاصرة والمختلطة. درسنا أيضاً تقنيات الشبكات العصبونية التي تعتبر أحد أساليب الذكاء الصناعي والتي يمكن أن استخدامها في التشخيص الطبي للمساعدة في نقل بعض خبرة الطبيب إلى الحاسب بحيث يتم الاستفادة من مزايا الحاسب في سرعة المعالجة والإظهار للنتائج، وهذا بدوره يساعد الأطباء في توفير الوقت والجهد المبذول لاتخاذ قرار التشخيص ومتابعة الحالات المرضية بشكل مستمر وتطورها والكشف المبكر علاوة على رفع مستوى الرعاية الصحية في هذا المجال.

تم استحصال عينات من جهاز وظائف الرئة PFT الموجود في مشفى الأسد الجامعي بالإضافة إلى عينات من الشركة الصانعة للجهاز تم استحصالها من أحد المشافي في إيطاليا. ثم تحليل وتصنيف العينات المستحصلة وتقسيمها لثلاث مجموعات مختلفة من حيث عدد العينات وعدد القياسات في كل عينة ومعالجتها لتكون جاهزة للإدخال للشبكة. بدأنا بعد ذلك بتصميم بنية الشبكة العصبونية المناسب لهذه الدراسة حيث وجدنا أن الشبكة العصبونية من النوع مستقبلات متعددة الطبقات MLP هو الأنسب، كما بحثنا في أنواع الخوارزميات الممكن استخدامها ودراسة متغيرات كل خوارزمية لمعرفة إمكانية تقسيم التجارب وتشكيل نماذج الشبكة العصبونية الأولى اللازمة لإجراء هذه التجارب. أعطت النتائج الأولية الناتجة من إجراء التجارب على العديد من خوارزميات التدريب (12 خوارزمية) إلى التركيز على أربعة نماذج للشبكات العصبونية من النوع MLP فقط وهي الخوارزميات التالية: Scaled Conjugate Gradient (SCG), Resilient Back-propagation (RB), Bayesian Regularization (BR), Levenberg Marquardt (LM) حيث أعطت هذه الخوارزميات أفضل النتائج خلال عملية التدريب. ثم نفذنا بعد ذلك عملية تقييم لهذه الخوارزميات وفق معايير أداء التصنيف المقترحة في الدراسة من حيث الدقة Accuracy والحساسية Sensitivity والنوعية Specificity والخطأ MSE وقيمة AUC والقيمة التنبؤية الموجبة PPV والسالبة NPV.

عملنا على تقييم نتائج الشبكة العصبونية المصممة مع نتائج برنامج جهاز وظائف الرئة PFT من حيث كافة المعايير الإحصائية التي ذكرناها في الفقرة السابقة، علماً أن البرنامج الموجود في جهاز وظائف الرئة لا يعتمد في تشخيصه على تقنيات الذكاء الصناعي كالشبكات العصبونية وغيرها بل يعتمد على معايير عالمية للتشخيص في هذا المجال تم كتابتها بأسلوب البرمجة التقليدية (IF-THEN rules). بينت النتائج التي حصلنا عليها تفوق الشبكات العصبونية على برنامج الجهاز مما يشير إلى نجاح تقنيات الشبكات العصبونية في مجال التشخيص الطبي للمساعدة في تحسين الدقة في تشخيص الأمراض.

قمنا أيضاً في هذه الدراسة باقتراح قياسين (معاملين) جديدين هما تحويل فورييه لمخططي (التدفق-الحجم) و(الحجم-الزمن) بحيث يمكن إضافتها لمجموع القياسات التي نأخذها من الجهاز.

تم فحص الشبكة العصبونية على ثلاثة مجموعات من العينات هي:

1-) المجموعة الأولى من بيانات الدخل و أطلقنا عليها الرمز 23p201 وتحتوي على 201 عينة ذات 23 قياس (شعاع الدخل للعينة الواحدة مكون من 23 مركبة).

2-) المجموعة الثانية من بيانات الدخل و أطلقنا عليها الرمز 13p380 والتي تحتوي على عدد عينات أكبر (380 عينة) ذات 13 قياس (شعاع الدخل للعينة الواحدة مكون من 13 مركبة).

3-) المجموعة الثالثة من بيانات الدخل و أطلقنا عليها الرمز 25p201 و هي نفس المجموعة الأولى و لكن بعد إضافة قياسين جديدين هما قيمة تحويل فورييه لكل من مخططي (التدفق-الحجم) و(الحجم-الزمن)، (شعاع الدخل للعينة الواحدة مكون من 25 مركبة).

أجرينا تجربة تقييم أداء الشبكة العصبونية والخوارزميات الأربعة على كل المجموعات الثلاثة أعلاه مع دراسة أثر عدد الطبقات المخفية ونوع التسوية المستخدم لبيانات الدخل و نوع تابع التفعيل. تم بعد ذلك مقارنة النتائج بالاعتماد على المعايير الإحصائية لتقييم دقة نتائج الشبكة العصبونية المصممة في تصنيف الحالات الأربعة المتعلقة بسلامة أو عدم سلامة جهاز التنفس للمريض. يمكن تلخيص النتائج التي حصلنا عليها كما يلي:

1- كانت معايير الأداء لتصنيف نماذج الشبكات العصبونية بالخوارزميات الأربعة المستخدمة أفضل من نتائج تقييم تصنيف برنامج جهاز وظائف الرئة PFT حيث زادت دقة التصنيف بمقدار 4% والحساسية بمقدار 4.5% والنوعية بمقدار 4% وقيمة AUC بمقدار 10% (الخوارزمية LM). الأمر الذي يدفعنا إلى التفكير بإمكانية تطوير برنامج التشخيص للجهاز بحيث نرفع من أداء التشخيص الآلي وسرعة الحصول على النتائج وسهولة الاستخدام كما هو مبين في الجدول (1-6) والشكل (5-6) في الفصل السادس.

2- هنالك علاقة وثيقة واضحة بين قياسات تقرير اختبار المريض باستخدام جهاز وظائف الرئة وبين الأصناف الأربعة المقترحة في هذه الدراسة: الحالة السليمة Normal والعلّة السادة Obstructive وعلّة القصور Restrictive والعلّة المختلطة Mixed. لكن يمكن أن تكون هذه العلاقة مشوشة أحياناً من أجل صنف العلة المرضية المختلطة كما هو موضح في الأشكال [a,b,c,d (3-5)] في الفصل الخامس.

3- دلت النتائج على فعالية وكفاءة استخدام الشبكات العصبونية وبخاصة نوع مستقبلات متعددة الطبقات MLP في نمذجة العلاقات غير الخطية والمعقدة بشكل جيد ودقة عالية عند تجهيز الشبكة العصبونية بالخوارزميات والمتغيرات المناسبة والتدريب لدرجة كافية.

4- أشارت النتائج إلى أن المعالجة الأولية لعينات الدخل للشبكة العصبونية وأسلوب التسوية المتبع وأنواع توابع التفعيل المستخدمة في العصبونات في كل طبقة إضافة إلى عدد الطبقات المخفية وعدد العصبونات في كل طبقة مخفية بحيث يتناسب مع تعقيد المسألة المطروحة مع تحديد الأوزان الابتدائية ومعدل التعلم المناسب كلها تساهم بشكل كبير في أداء التصنيف للشبكة. توضح الجداول (2-5) و(3-5) و(5-5) في الفصل الخامس هذه النتيجة.

5- تسوية بيانات الدخل وفق المجال [-1,+1] مع توابع تفعيل قطعية حقق نتائج أفضل منها في المجال [0,+1] مع توابع التفعيل اللوغاريتمية كما هو موضح في الجداول (2-5) و(3-5) و(5-5) في التجارب الثلاثة في الفصل الخامس.

6- تحديد معدل تعلم مناسب لخوارزمية التدريب في الشبكة ساهم في استقرار عملية التدريب من جهة وسرعة تقارب الخوارزمية من جهة أخرى.

7- زيادة أبعاد العينة الواحدة (أي كمية المعلومات التي تحويها كل عينة) يمكن أن يساهم بفعالية أكبر من إضافة عينات جديدة بأبعاد أقل لأن ذلك قد يخفض من فعالية التصنيف. يمكن أن يرجع نقص هذه الفعالية إلى نقص المعلومات الموجودة في العينة الأمر الذي قد يؤدي إلى

تصنيف خاطئ وانخفاض معايير الأداء للشبكة والتي من أهمها دقة التصنيف وبخاصة عند أعداد عينات منخفض نسبياً من أجل بعض الأصناف. يوضح الشكل (5-11) تقييم نتائج التجربة الأولى والشكل (5-12) تقييم نتائج التجربة الثانية في الفصل الخامس هذه النتيجة.

8- أشارت النتائج إلى أن أفضل الخوارزميات المستخدمة في تدريب هذا النوع من الشبكات في هذه الدراسة هي LM, BR, RB, SCG من حيث جودة معايير أداء التصنيف، وكانت خوارزمية LM هي الأفضل بينها، يبين الجدول (6-1) في الفصل السادس هذه النتائج.

9- ساهمت تقنية التوقف المبكر Early Stopping المستخدمة في خوارزمية التدريب للشبكة في زيادة قدرة الشبكة على التعميم أي تصنيف العينات التي لم تتدرب عليها من قبل بدرجة دقة مقاربة لدقة التدريب، علاوة على أنها قد جنبت الشبكة مشاكل مثل زيادة التدريب Over-fitting وزيادة الزمن اللازم للتعليم كما هو موضح في الجدول (5-9) والشكل (5-14) في الفصل الخامس.

أخيراً يمكن أن نذكر أن الشبكة العصبونية قد أعطت نتائج إيجابية مماثلة لتلك الواردة في الأوراق العلمية [3,4,18,19,21,23] من حيث نجاح الشبكات العصبونية لاستخدامها في التشخيص الطبي لوظائف الرئة عند الإنسان كما تم توضيحه في الجدول (2-5) في الفصل الثاني والجدول (6-2) في الفصل السادس، وبالتالي إمكانية استخدامها في التشخيص الآلي عن طريق إضافتها لجهاز وظائف الرئة كبديل أو خرج آخر مختلف عن برنامج الجهاز الذي يستخدم بناء تقليدي في التشخيص الآلي.

حسابياً، تفوقت الشبكة العصبونية على عدد من الشبكات العصبونية الواردة في الأوراق العلمية [3,18,21] كما هو مبين في الجدول (2-5) في الفصل الثاني والجدول (6-2) في الفقرة 6-8.

2-7 الصعوبات التي واجهناها خلال هذه الدراسة

1- واجهتنا صعوبة في جمع البيانات لزيادة عدد العينات المستخدمة في التدريب من أجل زيادة جودة النتائج النهائية، وهذا ما دفعنا لتجريب عدد من التراكيب المختلفة للشبكات العصبونية لملائمة عدد العينات والحصول على أفضل النتائج إلى أن وصلنا إلى النتائج التي ذكرناها.

2- كانت عملية إسناد القيم الابتدائية لأوزان الدخل Weights وقيم الانزياحات تتم بشكل عشوائي وبالتالي الحصول على قيم مختلفة للدقة والخطأ في التصنيف، الأمر الذي دفعنا إلى إجراء العديد من التجارب لانتقاء الأفضل منها.

- 3- أشارت نتائج استخدام قيمة مطال تحويل فورييه لمخططي (التدفق-الحجم) و (الحجم-الزمن) إلى بواذر مشجعة حيث أعطت نتائج أفضل من برنامج الجهار، و لكن لدى إضافتها إلى الشبكة العصبونية فقد أدت إلى تحسن قيمة الدقة بمقدار 1% والحساسية بمقدار 11% والنوعية بمقدار 1% في خوارزمية التدريب BR ولكن انخفضت قيمة الدقة بمقدار 1% والحساسية بمقدار 10% والنوعية بمقدار 2% في خوارزمية LM. نستنتج أن هذه القياسات يمكن استخدامها كمعاملات جديدة في الشبكات العصبونية ولكنها تحتاج إلى دراسة إضافية لمعالجة سبب انخفاض الدقة والحساسية والنوعية في بعض أنواع الخوارزميات المستخدمة.
- 4- يمكن أن تؤثر قلة عدد عينات أحد أصناف الأمراض التي يجري تصنيفها بالشبكة العصبونية إلى انخفاض ملموس في دقة التصنيف الإجمالية للشبكة العصبونية.

3-7 نصائح وآفاق مستقبلية للبحث

- 1- تحصيل عدد أكبر من العينات قد يساعد بشكل كبير في تحسين كفاءة تصنيف الشبكة العصبونية من جهة والتأكد من وثوقية النتائج التي حصلنا عليها من جهة ثانية.
- 2- على الرغم أنه تم العمل على اتباع عدة قواعد مرجعية لاسناد القيم الابتدائية للأوزان والانزياحات إلا أنها لم تنجح بالشكل المطلوب للحصول على القيم المثلى، لذلك فإن إيجاد طريقة لتحديد القيم المثلى للأوزان والانزياحات من أجل تركيبة شبكة عصبونية معينة قد يساعد كثيراً في زيادة كفاءة تصنيف الشبكة وتخفيض زمن البحث عن الحل المناسب.
- 3- تحليل مخططي (التدفق- الحجم) و (الحجم- الزمن) والحصول على قياسات رقمية من هذين المخططين بحيث تؤثر بشكل إيجابي وفاعل في عملية التصنيف للشبكة العصبونية عن طريق إعطاء مداخلها أوزان أكبر. نقترح على سبيل المثال استخدام طرق معالجة إشارة أخرى مثل Wavelet مثلاً أو غيرها.
- 4- استخدام قياسات تشخيصية جديدة من اختبارات أخرى يمكن استخلاصها من جهاز وظائف الرؤية مثل اختبارات انتشارية الغازات ضمن الحويصلات الرؤية (DLco Diffusion Capacity) الذي يمكن ان يساعد في توسيع قاعدة تصنيف الخرج إلى مجموعات مرضية أكثر يمكن أن تصل إلى 8 مجموعات مرضية. وهذا يتطلب دراسة مفصلة لهذا القياس وعلاقته في تشخيص هذه

الأمراض حسب المعايير العالمية والخبرة الطبية في هذا المجال. يوجد أيضا قياسات إضافية من الممكن الحصول عليها من جهاز وظائف الرئة مثل الإجراء المستخدم لحساب الحجم الكلي للرئة Total Lung Capacity (TLC) و التي تُسمى تقنية تنظيف الرئة باستخدام النتروجين Nitrogen Wash-out. نقترح أنه من الممكن لهذا القياس أن يساعد الأطباء في التشخيص ويعطي معلومات دقيقة عن حجم الهواء المتبقي في الرئة (RV) Residual Volume.

5- الانتباه إلى ضرورة الحصول على عدد عينات كافٍ في كل صنف من أصناف الأمراض المراد تدريب الشبكة العصبونية عليها وبخاصة من أجل أصناف الأمراض صعبة الكشف عملياً (من قبل الطبيب المختص).

الخلاصة:

احتوى هذا الفصل ملخص الأعمال في هذه الدراسة وأهم الاستنتاجات التي حصلنا عليها من إجراء التجارب في الفصول السابقة، بالإضافة إلى تأكيد فكرة تطوير أداء التشخيص الآلي لجهاز وظائف الرئة باستخدام الشبكة العصبونية وتبيان جدوى هذا التطوير من خلال توضيح تحسن أداء التصنيف. كما ذكرنا أهم الصعوبات التي واجهتنا خلال هذه الدراسة واقترحنا بعض الحلول الممكنة للدراسات اللاحقة المستقبلية لتطوير البحث في هذا المجال.

المراجع

1- المراجع الأجنبية:

[1]	S. Haykin, (1996) "Neural Networks/ A Comprehensive Foundation", Chapter 6, McMaster University. Hamilton. Ontario. Canada.
[2]	V. Brusasco, R. Crapo and G. Viegi, (2005) "Interpretative strategies for lung function tests", European Respiratory Journal, vol. 26 no. 5, pp. 948-968, Internal Medicine of Genoa Italy.
[3]	M. Baemani, A. Monadjemi and P. Moallem, (2008) "Detection of Respiratory Abnormalities Using Artificial Neural Networks" Journal of Computer Science, vol. 4 no. 8, pp. 663-667, University of Isfahan Iran.
[4]	S. Manoharan, M.Veezhinathan and S.Ramakrishnan, (2008) "Comparison of Two ANN Methods for Classification of Spirometer Data", Measurement Science Review, vol. 8, Section 2, no. 3, pp. 53-57, Anna University Chennai.
[5]	Kh. Mousa, M. Hani, T. Sugathan, T. Girma and B.O. Onadeko, (1999) "The Predictive Value Of Provisional Clinical Diagnosis In The Evaluation Of Respiratory Disorders", Annals of Saudi Medicine, vol. 19, no. 2, pp. 93-96, Kuwait University.
[6]	J. Peters and S. Levine, (2006) "Respiratory Disorders", section 3, Chapter 27 "Introduction to Pulmonary Function Test".
[7]	COSMED Company for Pulmonary Function Equipment: http://www.cosmed.it/index.php?option=com_content&view=article&id=239&Itemid=162&lang=en - May 6, 2013.
[8]	F. Al-Ashkar, R. Mehra and P. Mazzone, (2003) "Interpreting pulmonary function tests: Recognize the pattern, and the diagnosis will follow", Cleveland Clinic Journal of Medicine, vol. 70, no. 10, pp. 866-881.
[9]	E. Turban, R. Sharda and D. Delen, (2011) "Business Intelligence and Decision Support Systems (9th Ed., Prentice Hall)", Chapter 6 "Artificial Neural Networks for Data Mining", Pearson Education, Inc.

[10]	F. M. Ham and I. Kostanic, (2001) "Principle of Neurocomputing for Science and Engineering", Chapter 2 and 3, McGraw-Hill Higher Education companies, printed in Singapore.
[11]	H. Demuth, M. Beale and M. Hagan, (2009) "Neural Network Toolbox 6: User's Guide", MathWorks .Inc, 6 th ed.
[12]	D. Stathakis, (2009) "How many hidden layers and nodes?" International Journal of Remote Sensing, vol. 30, no. 8, pp. 2133-2147.
[13]	B. D. Storey "Computing Fourier Series and Power Spectrum with MATLAB", TEX Paper "Fourier Series", pp. 1-15.
[14]	W. Zhu, N. Zeng and N. Wang, (2010) "Sensitivity, Specificity, Accuracy, Associated Confidence Interval and ROC Analysis with Practical SAS Implementations", K&L consulting services- Inc- Fort Washington-PA, Octagon Research Solutions, pp. 9.
[15]	K. Waghmare, B. Wakode and P. Chatur, (2012) "Spirometry Data Analysis and Classification Using Artificial Neural Network: An Approach", International Journal of Emerging Technology and Advanced Engineering, vol. 2, issue 1, Government College Amravati Maharashtra India.
[16]	P. Junwale, A. Bhade and P. Chatur, (2012) "Statistical Data Mining Approach for Spirometric Data Classification: Review Paper", Inter. J. Computer Technology and Application, vol. 3, no. 1, pp. 348-351, ISSN 2229-6093, Government College Amravati Maharashtra India.
[17]	A. Kavitha, C. Sujatha and S. Ramakrishnan, (2012) "Prediction of Spirometric Forced Expiratory Volume (FEV1) Data Using Support Vector Regression", Measurement Science Review, vol. 10, no. 2, Anna University Chennai India.
[18]	O. Er, N. Yumusak and F. Temurtas, (2010) "Chest diseases diagnosis using artificial neural networks", Science Direct "Elsevier", pp. 7648-7655, Bozok University Yozgat Turkey.
[19]	S. Jafari, H. Arabalibeik and K. Agin, (2010) "Classification of Normal and Abnormal Respiration Patterns Using Flow Volume Curve and Neural Network", IEEE, pp. 110-113, Tehran University of Medical Sciences Tehran Iran.
[20]	A. Kavitha, M. Sujatha and S. Ramakrishnan, (2009) "Evaluation of Flow-Volume Spirometric Test Using Neural Network Based Prediction and Principal Component Analysis", Springer Science, DOI 10.1007/s10916-009-9349-7, pp. 127-133, Anna University Chennai India.

[21]	M. Veezhinathan and S. Ramakrishnan (2007) "Detection of Obstructive Respiratory Abnormality Using Flow-Volume Spirometry and Radial Basis Function Neural Networks", Springer Science, DOI 10.1007/s10916-007-9085-9, pp. 461-465, Anna University Chennai India.
[22]	S. Manoharan and S. Ramakrishnan, (2008) "Prediction of Forced Expiratory Volume in Pulmonary Function Test using Radial Basis Networks and k-means Clustering", Springer Science, DOI 10.1007/s10916-008-9196-y, pp. 347-351, Anna University Chennai India.
[23]	D. Sahin, E. Ubeyli and G. Ilbay, (2009) "Diagnosis of Airway Obstructive or Restrictive Spirometry Patterns by Multiclass Support Vector Machines", Springer Science, DOI 10.1007/s10916-009-9312-7, pp. 967-973, Kocaeli University Turkey.
[24]	V. Brusasco, R. Crapo and G. Viegi, (2005) "Standards of Spirometry", European Respiratory Journal, vol. 26, no. 2, pp. 319-338, Internal Medicine of Genoa Italy.
[25]	Global Initiative for Chronic Obstructive Lung Disease (2010) "Spirometry for Health Care Providers", website: http://www.goldcopd.org/uploads/users/files/GOLD_Spirometry_2010.pdf - April 3, 2013.

2- المراجع العربية:

[26]	يوسف مخلوف, مأمون حميد, صبحي البحري, (2011) "تشریح وفیزیولوجیا الطرق التنفسية العلوية والسفلية", مقررات السنة الثانية طب بشري للعام الدراسي 2010-2011 جامعة دمشق.
------	---

الملحقات

الملحق الأول: برنامج التدريب للشبكات العصبونية في بيئة الماتلاب

```

function
[optCorrTr,optCorrTe,opt1HidLayer,opt2HidLayer,optinitInW,optinit1LW,optini
t2LW,optinitInB,optinit1LB,optinit2LB,allResults] =
trainOptim2LTest(inputsTrain,targetsTrain,inputsTest,targetsTest,Max1Hidden
N,Max2HiddenN)
    optCorrTr=0;
    optCorrTe=0;
    allResults=[0 0 0 0];
for i=2:Max1HiddenN
    for k=2:Max2HiddenN
        net=newpr(inputsTrain,targetsTrain,[i k],{'tansig' 'tansig' 'tansig'});
        net=init(net);
        net.trainFcn='trainlm';
        net.divideFcn='divideint';
        initInW= net.IW{1,1};
        init1LW=net.LW{2,1};
        init2LW=net.LW{3,1};
        initInB=net.b{1,1};
        init1LB=net.b{2,1};
        init2LB=net.b{3,1};
        net=train(net,inputsTrain,targetsTrain);
        outputsTrain=sim(net,inputsTrain);
        outputsTest=sim(net,inputsTest);
        targetsTrainInd=compet(targetsTrain);
        outputsTrainInd=compet(outputsTrain);
        targetsTestInd=compet(targetsTest);
        outputsTestInd=compet(outputsTest);
        correctClass=0;
        missClass=0;
        for j=1:size(targetsTrain,2)
            if outputsTrainInd(1,j)==targetsTrainInd(1,j)
                correctClass=correctClass + 1;
            else
                missClass = missClass + 1;
            end
        end
        cTrain=correctClass;
        if (missClass + correctClass)~=size(outputsTrain,2)
            fprintf('Error in Correctly classified=%f - /Missclassified=%f
\n',missClass,correctClass);
        end
    end
correctClassTest=0;
missClassTest=0;
for j=1:size(targetsTest,2)
    if outputsTestInd(1,j)==targetsTestInd(1,j)
        correctClassTest=correctClassTest + 1;
    else
        missClassTest = missClassTest + 1;
    end
end
cTest=correctClassTest;

```

```

        if (missClass + correctClass)~=size(outputsTrain,2)
            fprintf('Error in Correctly classified=%f - /Missclassified=%f\n',missClass,correctClass);
        end

        resultRow=[i k correctClass correctClassTest];
        allResults=[allResults;resultRow];

        if cTest > optCorrTe
            optCorrTe=cTest;
        end

        if cTrain > optCorrTr
            optCorrTr=cTrain;
            opt1HidLayer=i;
            opt2HidLayer=k;
            optinitInW=initInW;
            optinit1LW=init1LW;
            optinit2LW=init2LW;
            optinitInB=initInB;
            optinit1LB=init1LB;
            optinit2LB=init2LB;
        end
    end
end
    return
end

```

```

function [ro, auc, avgauc, acc, sens, spec, ppv, npv, c, cm, ind, per] =
calRocAuc(targets, actualoutputs)
nTarget=targets(1,:);
oTarget=targets(2,:);
rTarget=targets(3,:);
mTarget=targets(4,:);
nOutput=actualoutputs(1,:);
oOutput=actualoutputs(2,:);
rOutput=actualoutputs(3,:);
mOutput=actualoutputs(4,:);
[tprn, fprn, thresholds] = roc(nTarget, nOutput);
[tpro, fpro, thresholdso] = roc(oTarget, oOutput);
[tpr, fpr, thresholdsn] = roc(rTarget, rOutput);
[tprm, fprm, thresholdsm] = roc(mTarget, mOutput);
aucN=areaundercurve(fprn, tprn);
aucO=areaundercurve(fpro, tpro);
aucR=areaundercurve(fpr, tpr);
aucM=areaundercurve(fprm, tprm);
auc=[aucN aucO aucR aucM];
avgauc=(aucN+aucO+aucR+aucM)/4;
ro=[fprn; tprn; fpro; tpro; fpr; tpr; fprm; tprm];
[c, cm, ind, per] = confusion(targets, actualoutputs);
tn=cm(1,1);
tp=cm(2,2)+cm(3,3)+cm(4,4)+cm(2,3)+cm(2,4)+cm(3,2)+cm(3,4)+cm(4,2)+cm(4,3);

```

```

fn=cm(2,1)+cm(3,1)+cm(4,1);
fp=cm(1,2)+cm(1,3)+cm(1,4);
acc=(tn+tp)/(tn+tp+fn+fp);
sens=tp/(tp+fn);
spec=tn/(tn+fp);
ppv=tp/(tp+fp);
npv=tn/(tn+fn);
end

```

```

function auc=areaundercurve(FPR,TPR);
    [x2,inds]=sort(FPR);
    x2=[x2,1]; % the trick is in inventing a last point 1,1
    y2=TPR(inds);
    y2=[y2,1];
    xdifff=diff(x2);
    xdifff=[x2(1),xdifff];
    auc1=sum(y2.*xdifff); % upper point area
    auc2=sum([0,y2([1:end-1])].*xdifff); % lower point area
    auc=mean([auc1,auc2]);
end

```

```

function
[optCorrTr,optCorrTe,optinitInW,optinit1LW,optinit2LW,optinitInB,optinit1LB,
optinit2LB,allResults,optnet,outputTrain,ro,auc,avgauc,acc,sens,spec,ppv,npv,
c,cm,ind,per,outputbin,revoutput,roT,aucT,avgaucT,acCT,sensT,spect,ppvT,
npvT,cT,cmT,indT,perT,revoutputT] =
trainOptim2LTestInitResults(inputsTrain,targetsTrain,inputsTest,targetsTest
,Max1HiddenN,Max2HiddenN)
    optCorrTr=0;
    optCorrTe=0;
    allResults=[0 0 0 0 0];
for i=1:200
    net=newpr(inputsTrain,targetsTrain,[Max1HiddenN Max2HiddenN],{'tansig'
'tansig' 'tansig'});
    net=init(net);
    net.trainFcn='trainlm';
    net.divideFcn='divideint';
    initInW= net.IW{1,1};
    init1LW=net.LW{2,1};
    init2LW=net.LW{3,1};
    initInB=net.b{1,1};
    init1LB=net.b{2,1};
    init2LB=net.b{3,1};
    net=train(net,inputsTrain,targetsTrain);
    outputsTrain=sim(net,inputsTrain);
    outputsTest=sim(net,inputsTest);
    targetsTrainInd=compet(targetsTrain);
    outputsTrainInd=compet(outputsTrain);
    targetsTestInd=compet(targetsTest);
    outputsTestInd=compet(outputsTest);
    correctClass=0;
    missClass=0;
end

```

```

for j=1:size(targetsTrain,2)
    if outputsTrainInd(1,j)==targetsTrainInd(1,j)
        correctClass=correctClass + 1;
    else
        missClass = missClass + 1;
    end
end
cTrain=correctClass;
if (missClass + correctClass)~=size(outputsTrain,2)
    fprintf('Error in Correctly classified=%f - /Missclassified=%f\n',missClass,correctClass);
end
correctClassTest=0;
missClassTest=0;
for j=1:size(targetsTest,2)
    if outputsTestInd(1,j)==targetsTestInd(1,j)
        correctClassTest=correctClassTest + 1;
    else
        missClassTest = missClassTest + 1;
    end
end
cTest=correctClassTest;
if (missClass + correctClass)~=size(outputsTrain,2)
    fprintf('Error in Correctly classified=%f - /Missclassified=%f\n',missClass,correctClass);
end
resultRow=[i Max1HiddenN Max2HiddenN correctClass correctClassTest];
allResults=[allResults;resultRow];
if cTest > optCorrTe
    optCorrTe=cTest;
end
if cTrain > optCorrTr
    optCorrTr=cTrain;
    optnet=net;
    optinitInW=initInW;
    optinit1LW=init1LW;
    optinit2LW=init2LW;
    optinitInB=initInB;
    optinit1LB=init1LB;
    optinit2LB=init2LB;
end
end
outputTrain=sim(optnet,inputsTrain);
[ro, auc, avgauc, acc, sens, spec, ppv, npv, c, cm, ind, per] =
calRocAuc(targetsTrain,outputTrain);
outputbin=out2bin(outputTrain);
revoutput=outputbin';
outputTest=sim(optnet,inputsTest);
[roT, aucT, avgaucT, accT, sensT, specT, ppvT, npvT, cT, cmT, indT, perT] =
calRocAuc(targetsTest,outputTest);
outputbin=out2bin(outputTest);
revoutputT=outputbin';
return
end


```


الملحق الثاني: نتائج بعض الحالات التدريبية لمجموعات البيانات المختلفة

مثال (1) ملحق: شبكة عصبونية متعددة الطبقات ومجموعة بيانات الدخل 23×201 بالإعدادات والنتائج الموضحة في الجدول (1) والشكل (1) التالية:

الجدول (1) إعدادات الشبكة العصبونية مثال (1) ملحق

Neural Network (MLP) Parameters (case – 2)			
Layer	Neurons Count	Activation Function	Normalization
Input	23	Sigmoidal	[0,+1]
Hidden 1	31	Sigmoidal	[0,+1]
Output	4	Sigmoidal	[0,+1]
Error	Epoch	Learning Rate	Training Algorithm
0.0673	8	0.001	Levenberg Marquardt
Dim*Samples		Training	Validation
23*201		151	40
Data Input	Accuracy	Sensitivity	Specificity
Training Set	0.93	0.89	0.99





الشكل (b1) يوضح منحنيات تابع الخطأ MSE لكل من مجموعة التدريب بالأزرق والتوثيق بالأخضر والفحص بالأحمر مع تغير عصور التدريب epochs

الشكل (a1) يوضح مخططات ROC المتعلقة بكل من مجموعة التدريب والتوثيق والفحص والمجموعة الكلية، كل لون من الألوان في الشكل يمثل منحنى ROC الخاص بكل صنف من أصناف الأمراض الأربعة التي يجري تصنيفها


الشكل (1) أحد أفضل النتائج التي حصلنا عليها أثناء التدريب (طبقة مخفية وحيدة) مثال (1) ملحق

مثال (2) ملحق : شبكة عصبونية متعددة الطبقات ومجموعة بيانات الدخل 13*380 بالإعدادات والنتائج الموضحة في الجدول (2) والشكل (2) التالية:

الجدول (2) إعدادات الشبكة العصبونية المثال (2) ملحق

Neural Network (MLP) Configurations (Example-2)			
Layer	Neurons Count	Activation Function	Normalization
Input	13	Hyperbolic Tangent	[-1,+1]
Hidden 1	7	Hyperbolic Tangent	[-1,+1]
Hidden 2	24	Hyperbolic Tangent	[-1,+1]
Output	4	Hyperbolic Tangent	[-1,+1]
Error	Epoch	Learning Rate	Training Algorithm
0.0759	9	0.001	Levenberg Marquardt
Dim*Samples		Training	Validation
			Testing


13*380	228	76	76
Accuracy	Sensitivity		Specificity
0.922	0.843		0.942



مثال (3) ملحق: شبكة عصبونية متعددة الطبقات ومجموعة بيانات الدخل 23*201 بالإعدادات والنتائج الموضحة في الجدول (3) والشكل (3) التالية:


الجدول (3) إعدادات الشبكة العصبونية المثال (3) ملحق

Neural Network (MLP) Configurations (Example-3)			
Layer	Neurons Count	Activation Function	Normalization
Input	23	Hyperbolic Tangent	[-1,+1]
Hidden 1	34	Hyperbolic Tangent	[-1,+1]
Hidden 2	27	Hyperbolic Tangent	[-1,+1]
Output	4	Hyperbolic Tangent	[-1,+1]
Error	Epoch	Learning Rate	Training Algorithm
0.0573	27	0.001	Scaled Conjugate Gradient
Dim*Samples	Training	Validation	Testing
23*201	121	40	40
Accuracy	Sensitivity	Specificity	
0.948	0.678	0.984	




الملحق الثالث: نتائج تقييم أداء الشبكة العصبونية على مجموعات بيانات الدخل الثلاث

(1) نتائج تقييم أداء الشبكة العصبونية على مجموعة البيانات الأولى (مجموعة الفحص):




الشكل (1) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Levenberg Marquardt مع عينات التدريب 201 ذات 23 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC




الشكل (2) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Bayesian Regularization مع عينات التدريب 201 ذات 23 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

Resilient Backpropagation - 23 p 201 samples




الشكل (3) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Resilient Backpropagation مع عينات التدريب 201 ذات 23 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

Scaled Conjugate Gradient -23 p 201 samples




الشكل (4) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Scaled Conjugate Gradient مع عينات التدريب 201 ذات 23 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

(2) نتائج تقييم أداء الشبكة العصبونية على مجموعة البيانات الثانية (مجموعة الفحص):




الشكل (5) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Levenberg Marquardt مع عينات التدريب 380 ذات 13 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC




الشكل (6) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Bayesian Regularization مع عينات التدريب 380 ذات 13 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

Resilient Backpropagation - 13 p 380 samples




الشكل (7) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Resilient Backpropagation مع عينات التدريب 380 ذات 13 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

Scaled Conjugate Gradient -13 p 380 samples




الشكل (8) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Scaled Conjugate Gradient مع عينات التدريب 380 ذات 13 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

(3) نتائج تقييم أداء الشبكة العصبونية على مجموعة البيانات الثالثة (مجموعة الفحص):




الشكل (9) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Levenberg Marquardt مع عينات التدريب 201 ذات 25 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC




الشكل (10) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Bayesian Regularization مع عينات التدريب 201 ذات 25 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

Resilient Backpropagation - 25 p 201 samples





الشكل (11) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Resilient Backpropagation مع عينات التدريب 201 ذات 25 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC


Scaled Conjugate Gradient -25 p 201 samples



الشكل (12) تقييم نظام تصنيف الشبكة العصبونية ذات خوارزمية التدريب Scaled Conjugate Gradient مع عينات التدريب 201 ذات 25 قياس، يتضمن الدقة والحساسية والنوعية والقيمة التنبؤية للحالات الايجابية والسلبية و AUC

الملحق الرابع: الأجزاء الرئيسية في جهاز اختبار وظائف الرئة PFT والمخطط الصندوقي لعمل الجهاز





المواصفات الفنية لجهاز اختبار وظائف الرئة PFT من تصنيف شركة COSMED الإيطالية [7]:

1- يعتمد الجهاز على تقنية العنفة الهوائية الدوارة Turbine لقياس حجم وتدفق الهواء أثناء عملية الشهيق والزفير، حيث يتحدد التدفق بسرعة دوران هذه العنفة والحجم بعدد الدورات ويتم التقاط كل من هذه السرعة وعدد الدورات بواسطة زوجين من مرسل-مستقبل للأشعة تحت الحمراء كما هو موضح في الشكل (14).

2- إن جهاز Quark PFT نظام متكامل مكون من عدة وحدات (Modules) لقياس وظائف الرئة ومربوط مع حاسب يعمل مع بيئة Windows.

3- يقيس العديد من البارامترات نذكر منها: VC, FVC, FEV, FEF, FIV, PIF, MVV,

Slow VC/forced VC, Static lung volume SVC, IC, ERV, FEV/VC,

4- إمكانية إجراء مقارنة نتائج الاختبارات قبل وبعد إعطاء الموسع القسبي واستخلاص نسبة التحسن عن طريق Broncho challenge test والذي يعتبر من أحد الفحوصات الأساسية في اختبارات وظائف الرئة.

5- يتم إظهار منحنيات التدفق / الحجم ومنحنيات الحجم / الزمن على الشاشة خلال الفحص وبعد الانتهاء, كما يتم إظهار المنحنيات بعدة ألوان مختلفة عند إعادة إجراء الاختبار لأكثر من مرة وذلك لسهولة المقارنة بين النتائج .

6- دقة القياسات $\pm 2\%$.

7- مزود بإمكانية إجراء اختبار انتشار الغازات DLCO كالتالي:

- يمكن قياس الغاز بالزمن الحقيقي بطريقة حبس النفس.
- يمكن قياس الغاز بالزمن الحقيقي بدون الحاجة لحبس النفس.
- يمكن التحكم بحجم العينة و حجم الغاز المرفوض لقياسات المريض من خلال تقليل السعة الحيوية.

8- يمكن قياس حجوم الرئة باستخدام النتروجين النقي من خارج الغرفة. Nitrogen washout

RV- FRC- TLC

9- الجهاز مزود بحاسب من إنتاج شركة Dell العالمية، بالمواصفات التالية:


- OptiPlex 760 Desktop – Desktop Chassis
- CPU: Intel Core 2 Duo E7400 (2.8 GHz, 1066MHz, 3MB)
- RAM: 4GB Ram
- Hard Drive: 250GB (7,200 rpm) SATA
- DVD: 16X DVD+/- RW Drive + Sonic RW
- Audio: Integrated sound card

- Network: Included
 - Dell 2 Button USB Midnight Grey keyboard
 - Monitor 22"
 - Laser printer
 - نظام التشغيل: Microsoft Windows 7
- 10- يمكن أرشفة بيانات كل مريض و حفظها و نقلها من وإلى أي نوع من أنواع أدوات الحفظ (DVD, CD, Flash memory) ، مع إمكانية الربط على شبكة المشفى من خلال كرت الشبكة.
- 11- الجهاز المقدم حاصل على شهادات الجودة العالمية التالية FDA (MDD(93/42 EEC) : 510(K), EN 6061-1(Safety)0 EN60601-1-2(EMC)
- 12- حساسات التدفق الثنائية الاتجاه تتميز بدقتها العالية خلال مجال يصل حتى (20 لتر/ ثانية).
- 13- إمكانية التعديل على منحنيات الفحوصات وخاصة المحاور الأساسية بشكل سهل.
- 14- إمكانية ربط وإظهار نتائج جميع فحوصات المريض للمقارنة فيما بينها.
- 15- إمكانية تصدير نتائج الاختبارات إلى ملفات (Excel, ASCII) .
- 16- البرنامج متوافق مع أي شبكة محلية تعمل على نظام Windows .
- 17- يعمل على التيار المتناوب 240/100 فولط $\pm 10\%$, 50-60 هرتز ، استطاعة الجهاز 100واط.

تقنيات أخرى مستخدمة في حساب بارامترات جهاز قياس التنفس Spirometer [R. Schlegelmilch and R. Karmme]

1) مقاييس التنفس الحجمية Volumetric Spirometers: مثل الجرس المائي Water bell الذي يعتبر من أولى التقنيات المستخدمة في لقياس بارامترات التنفس والذي يعتمد على قياس حجم هواء الشهيق والزفير مباشرة من حجم السائل المزاح خلال عملية التنفس لنقل هذه الحركة إلى

جرس يتحكم بآلية رسم منحنى التنفس ثم استنتاج وحساب البارامترات (الحجوم والسعات والتدفقات), كما هو موضح في الشكل (16).



الشكل (16) مخطط لمقياس التنفس المعتمد على تقنية الجرس المائي water bell, ملحق (4)

2) مقاييس التنفس التي تعتمد على قياس التدفق Flow measuring Spirometers لحساب الحجوم: تعتمد هذه الطرق على قياس التدفق بواسطة حساس تدفق ثم حساب تكامل هذا التدفق رقمياً للحصول على الحجم وفق المعادلة التالية:

$$V = \int \dot{V} dt$$

حيث ترمز V إلى حجم هواء الزفير أو الشهيق وترمز $\dot{V} = dV/dt$ (1/s) إلى التدفق المقاس.

نذكر من تقنيات قياس التدفق ما يلي:


a. حساس التدفق Fleisch-pneumotach الذي يعتمد على مبدأ حساب فرق الضغط

بين طرفي حزمة من القنوات الشعرية الدقيقة التي تشكل مقاومة هوائية ثابتة, يتم حساب

التدفق وفق قانون Hegen-Poiseuille الذي يعطى في حالة التدفق الصفائحي بالمعادلة التالية:

$$\Delta p = c \cdot \dot{V} = \frac{8\eta l}{r^4} \dot{V}$$

حيث أن c هو ثابت لزوجة الغاز وتصميم الحساس، يرمز l لطول أنبوب الحساس و r هو نصف قطر أنبوب الحساس و η هو ثابت اللزوجة و $\dot{V}$ هو معدل التدفق، يوضح الشكل (17) مقطع عرضي في أنبوب هذا الحساس ومتطلبات استنتاج إشارة الحجم.




b. حساس التدفق نوع Lilly-Pneumotachometer: إصدار مطور من النوع Fleisch-pneumotach تكون فيه حزمة الأنابيب الشعرية المقاومة للهواء على شكل شبكة هوائية، ويتميز هذا النوع بالفرق الكبير بين قطر الأنبوب وقطر الشبكة المقاومة للهواء.

c. مقياس التدفق التوربيني (ذو العنفة الهوائية) Turbine: الذي تم استخدامه في هذه الدراسة وذكرت تقنية القياس فيه سابقاً في مطلع الملحق الرابع.

d. مقياس التدفق التدفق الحراري (Hot-wire (anemometer): هو عبارة عن أنبوبة فينتوري Venturi يحتوي على سللي تسخين متصلين إلى دارة الكترونية جسرية (جسر واتسطن Wheatstone). يتكون أحد السللين من نوعين من البلاتينيوم وهو الذي يتحسس لحرارة الغاز, بينما يقيس السلك الآخر فيض التسخين عبر الغاز الذي يعبر الأنبوب. بالتالي يكون فيض ذو درجة الحرارة المصححة متناسباً مع تدفق الغاز عبر الأنبوب.

e. قياس التدفق بالأمواف فوق الصوتية Ultrasound: تعتمد هذه التقنية على تحديد أزمدة العبور للأمواف الصوتية المنقطة عبر وسط متحرك (متدفق مثل الغازات). تزداد سرعة الأمواف الصوتية عبر أنبوب من الغازات الجارية بنفس معدل زيادة سرعة الهواء في هذا الأنبوب, يوضح الشكل (18) مقطع عرضي في حساس التدفق بالأمواف فوق الصوتية:



الشكل (18) مقطع عرضي في حساس التدفق بالأمواف فوق الصوتية Ultrasound, ملحق (4)

من الشكل (18) نجد أنه يتم تحديد زمن العبور للأمواف فوق الصوتية بين المرسل (Transducer1) والمستقبل (Transducer2) والذي يسمى Time-of-flight

impulse ويكون عندها الفرق في أزمنة العبور متناسب مع سرعة التدفق التي تكون مستقلة عن المتغيرات الأخرى المحيطة مثل حرارة الغاز واللزوجة والرطوبة.


مخططات إضافية تستخدم بشكل شائع في تشخيص أمراض الجهاز التنفسي [Z. Almudheffer :2012]

أولاً: مخططات ضغط غشاء الجنب Pleural Pressure وتغيراتها خلال عملية التنفس:

تعريف ضغط غشاء الجنب: هو ضغط السائل في الفراغ الضيق الكائن بين غشاء جنب الرئة وغشاء جنب الجدار الصدري. تكون قيمة ضغط غشاء الجنب في بداية عملية الشهيق في الحالات الطبيعية حوالي -5 سنتيمتر من الماء والذي يمثل كمية التخلية (الضغط السلبي) المطلوبة لإبقاء الرئة مفتوحة في حالاتها الطبيعية. يحدث خلال عملية الشهيق الطبيعية أن تبتعد أضلاع القفص الصدري عن الرئة لتشكل ضغط سلبي أكبر من الضغط الجوي النظامي، حيث يسمح بدخول الهواء للرئة وقد تصل قيمة هذا الضغط إلى -7.5 سنتيمتر ماء. يوضح الشكل (19) العلاقات بين ضغط غشاء الجنب وضغط الأسناخ الرئوية مع تغيرات حجم الرئة. يبين المنحني السفلي (تغيرات الضغط باللون الأزرق) في الشكل (19) الزيادة في القيمة السالبة لضغط غشاء الجنب من -5 إلى -7.5 خلال عملية الشهيق، بينما يبين المنحني العلوي (تغيرات حجم الرئة باللون الأحمر) زيادة حجم الرئة بقيمة 0.5 لتر. بعد انتهاء طور الشهيق يبدأ طور الزفير الذي فيه تتم إعادة نفس الأحداث ولكن بشكل عكسي.

يوضح الشكل (19) أيضاً تغيرات حجم الرئة مع قيم ضغط الأسناخ الرئوية، الذي هو ضغط الهواء داخل السنخ الرئوي. عندما يكون لسان المزمار مفتوحاً وليس هنالك أي تدفق هواء داخل أو خارج من الرئة فإن قيمة الضغط في كامل الشعب الهوائية في الجهاز التنفسي وطرق الأسناخ الرئوية تكون مساوية للضغط الجوي الذي يعتبر الضغط المرجعي في المجاري الهوائية (أي 0 سنتيمتر ماء). تبدأ عملية الشهيق بإحداث انخفاض ضئيف في قيمة الضغط ضمن السنخ الرئوي عن قيمة الضغط الجوي النظامي (الصفير المرجعي) لتصل في الحالات الطبيعية لقيمة -1 سنتيمتر ماء. تكفي هذه القيمة السالبة لسحب ما يقارب 0.5 لتر من الهواء لداخل الرئة خلال زمن قدره 2 ثانية في الحالات السليمة. من جهة أخرى تحصل


نفس الخطوات خلال عملية الزفير حيث يزداد الضغط في السنخ الرئوي لحوالي +1 سنتيمتر ماء الأمر الذي يسبب تفريغ ما يقارب 0.5 لتر من الهواء خارج الرئة خلال زمن يتراوح بين 2 إلى 3 ثانية.



ثانياً: مخطط مطاوعة الرئتين Compliance of the lungs:

تعريف مطاوعة الرئة: هي قدرة الرئة على الاتساع والتي فيها تتمدد كل وحدة لتساهم في زيادة فرق الضغط بين الأسناخ وغشاء الجنب والمسمى الضغط الرئوي الانتقالي Transpulmonary pressure (إذا توفر الزمن الكافي لبلوغ التوازن). تبلغ القيمة الإجمالية لكلا الرئتين في الحالات الطبيعية لإنسان بالغ متوسط قدره 200 ميليمتر، بينما تبلغ قيمة المطاوعة لكامل نظام الرئة مع الحنجرة نصف قيمة

مطاوعة الرئة لوحدها أي 110 ميليمتر حجم لكل سنتيمتر ضغط وذلك مقارنة مع قيمة 200 ml/cm من أجل الرئة لوحدها كما هو موضح في الشكل (20).



الشكل (20) مخطط مطاوعة الرئة لشخص طبيعي , ملحق (4)

عند تقدير القيمة الساكنة لمطاوعة الرئة لابد من قياس قيم الضغط الرئوي الانتقالي Transpulmonary pressure بواسطة مبدلات ضغطية بشكل متزامن مع قياسات الحجم المجراة بجهاز قياس التنفس Spirometer. عندها يمكن أن نحصل على منحنى يمثل العلاقة بين تغيرات الحجم مع تغيرات قيم الضغط الرئوي الانتقالي تكون فيه قيمة مطاوعة الرئة الساكنة هي ميل المنحنى عند أي حجم معطى أو هي رياضياً $\Delta V / \Delta P$. يعتبر قياس مطاوعة الرئة من أكثر القياسات حساسية لكشف الحالات غير الطبيعية في آلية التنفس في الرئة، حيث تكون في الحالات الطبيعية ضمن المجال من 60% إلى 140% كقيمة متوسطة للتعداد السكاني من أجل أي شخص بنفس العمر والجنس وتركيب الجسم.

لماذا تم اختبار جهاز وظائف الرئة PFT في هذه الدراسة؟

- 1- جهاز متطور وسهل الاستخدام.
- 2- قابل للمعايرة بشكل يومي للتأكد من دقة القياس (لأنه يعتمد على مبدأ العنفة الهوائية Turbine):
يتم ذلك باستخدام محقنة Syringe ذات حجم ثابت دقيق (3 لتر), يتم حقن كامل حجم الهواء ضمن أنبوب العنفة الهوائية (التي يتم تركيبها عند الفوهة) عدة مرات متتالية وبسرعات مختلفة.
يجب الأخذ بعين الاعتبار أن عملية الحقن هذه تطبق على للعنفة بحيث تسمح للشفرات بالدوران بالاتجاهين (أي حقن يليه سحب) حتى تجري عملية المعايرة لكل من هواء الشهيق والزفير.
- 3- إن إمكانية الاتصال مع جهاز حاسب شخصي وشاشة عرض تتيح خيارات متنوعة مثل سهولة معالجة البيانات وتخزينها وإرشفتها ونقلها لحاسب آخر وفق ملفات من نوع Excel.
- 4- بعض أنواع من هذه الأجهزة مثل الـ Spirometer التقليدي وأجهزة وظائف الرئة الصغيرة المحمولة يمكن أن لا يوفر خيارات واسعة للأرشفة ونقل البيانات ومعالجتها وإظهارها.
- 5- إمكانية الوصول للجهاز في مشفى الأسد الجامعي.

الملحق الخامس: جدول خوارزميات الانتشار الخلفي Back-propagation المستخدمة في تدريب الشبكة العصبونية المصممة نوع (MLP) Multi-Layer Perceptron واختصاراتها في بيئة العمل الماتلاب

الجدول (4) جدول الخوارزميات المستخدمة في تدريب الشبكة العصبونية المصممة نوع Multi-Layer Perceptron ((MLP واختصاراتها في بيئة العمل الماتلاب [11]

#	اسم خوارزمية Back-propagation	اختصار تابع الخوارزمية في بيئة الماتلاب
1	Levenberg Marquardt (LM)	trainlm
2	Bayesian Regularization (BR)	trainbr
3	Scaled Conjugate Gradient (SCG)	trainscg
4	Resilient Back-propagation (RP)	trainrp
5	Gradient Descent with Momentum and Adaptive learning rate rule (GDM)	traingdm
6	Polak-Ribiere Conjugate Gradient (CGP)	traincgp
7	One Step Secant (OOS)	trainoss
8	Fletcher-Powell Conjugate Gradient (CGF)	traincgf
9	Powell-Beale Conjugate Gradient (CGB)	traincgb
10	Gradient Descent with Adaptive Learning Rule (GDA)	traingda
11	Gradient Descent (GD)	traingd
12	Sequential Order Incremental Training with Learning Functions	trains

Abstract

The increased needs to have a successful, fast diagnosis of respiratory diseases were the inspiration for many practitioners and engineers to improve helpful methods for early detection by using Artificial Neural Network (ANN) techniques. ANN, one of the smartest ways to model such these complicated systems, were exploited to be an intelligent tool in assisting diagnosis of pulmonary diseases by using Multi-Layers Perceptron (MLP) and several varieties of parameters such as FVC, FEV1, FEF, ...etc. Spirometer samples, up to 581, were classified by ANN into 4 classes; normal, obstructive, restrictive and mixed. In addition to, many training algorithms together with adding extra parameters based on Fast Fourier Transformer (FFT) of flow-volume and volume-time curve and evaluating the results by several criteria including accuracy, sensitivity, specificity and ROC. Moreover, comparisons among several methods such as ANN, device diagnostic program, and many training algorithms of MLP have been discussed and evaluated. Based on many experiments in this study, Levenberg Marquardt (ML) algorithm has fulfilled the best classification accuracy results due to its fast performance and embedded early stopping technique. Acquired Results recommended supplying such these spirometer devices with techniques based on ANN in which the expertise of doctors could be employed smartly to help in diagnosis instead of traditional programs (non-ANN techniques) due to the reliability and the better classification accuracy achieved in its intelligent algorithms. Additionally, the research suggested an approach to make use of both main flow-volume and volume-time curves so that they could be used as distinct features in respiratory diseases' diagnosis.

Syrian Arab Republic

Damascus University

Faculty of Mechanical & Electrical Engineering

Biomedical Engineering Department



Using of Computerized Diagnosis in evaluation of Pulmonary Function Test's Results to help in Diagnosis of Respiratory Diseases

**Thesis submitted for the degree of Master of Science MSc. in Biomedical
Engineering Department**

By

Eng. Ahmad Almazloun

Supervisor

**Dr. Eng. Abdel Razzak
Al-Hinnawi**

Co-supervisor

**Dr. Maisaa Abou-
Alkasem**

Academic Year
2012-2013