

استخدام الشبكات العصبونية الصناعية للتنبؤ بقوة شدّ الألياف القطنية

د. م. حسين تينة*

م. عبير العسود***

م. غاندي أحمد**

الملخص

تُعدّ قوة شد الليف من الخواص المهمة التي تميّز ألياف القطن بعضها عن بعض. وتُعدّ متحولاً مهماً لتقييم جودة الألياف مع ملاحظة أن لها تأثيراً مباشراً في قوة شد الخيط المنتج من هذه الألياف. هدَفَ هذا البحث إلى تقديم طريقة للتنبؤ بقوة شد الليف القطني باستخدام الشبكات العصبونية الصناعية إذ اختيرت (مؤشر الشعيرات القصيرة، ونعومة الألياف، وتناظم طول الألياف، وطول الألياف، وعدد العقد، ونسبة الشوائب) كمدخلات للشبكة العصبونية، في حين قوة شد الليف القطني كمرج للشبكة. أُجريت الاختبارات وجمعت النتائج في الشركة العامة للخبوط القطنية (الساحل) - اللاذقية. بلغ عدد الاختبارات التي جمعت من هذه الشركة (103) اختبارات. تظهر نتائج البحث أن طريقة التنبؤ باستخدام الشبكات العصبونية الصناعية فعالة وناجحة. وقد أُجريت مقارنة بين خرج الشبكة العصبونية والنتائج المخبرية، وكانت نسبة الخطأ الداخلي في أداء الشبكة نحو 1.1%.

الكلمات المفتاحية: قوة شد الليف، الشبكات العصبونية الصناعية، قطن، التنبؤ.

* أستاذ - قسم الميكانيك - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

** ماجستير تكنولوجيا غزل - مهندس في قسم ميكانيك الصناعات النسيجية وتقاناتها - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

*** طالبة ماجستير. مهندسة في قسم ميكانيك الصناعات النسيجية وتقاناتها - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

1. المقدمة:


جودة الليف القطني لها تأثير مهم في جودة خيوط الغزل الناتجة عنها لذا يمكن التنبؤ بخصائص جودة الخيوط مثل خصائص قوة الشد من خصائص المواد الأولية التي كانت الهدف الأساسي للعديد من الباحثين في السنوات الماضية. أُجريت المحاولة لمعرفة العلاقات بين خصائص الليف القطني وخصائص الخيوط الناتجة عنه. وهذا بدوره أظهر أهمية التنبؤ بجودة الخيوط بالاستناد إلى المعلومات التي يتم الحصول عليها من جودة الليف وذلك باستخدام الطرائق الإحصائية والرياضية.

فمثلاً استنتج Pan [12] العلاقة التي تربط بين قوة شد الخيط وقوة شد الليف بالاعتماد على الطرائق الإحصائية. طور Lyengar [10،11] علاقات تضمنت طول الألياف، نعومتها وعدم انتظامية الطور من أجل التنبؤ بتماسك الخيوط المغزولة. في حين أعطى Hafez [8] صيغة للتنبؤ بقوة الشلة وقوة شد الخيط المفرد. في حين أوجد Ethridge et al [5] علاقة تجريبية خطية بين قوة شد الخيط التوربيني وقوة شد الألياف والنعومة ومعدل انتظام طول الألياف ورماديتها إذ أشار إلى أن قوة شد الألياف وانتظام الطول ذو ارتباط إيجابي مع قوة شد الخيط.

في السنوات الأخيرة أظهر الباحثون اهتماماً في استعمال الشبكات العصبونية الصناعية (ANN) من أجل التنبؤ بخصائص الخيوط [6]. التي كان لها أثر بالغ في حل العديد من المشكلات المعقدة للاخطية. أظهر كثير من الباحثين أن أداء التنبؤ للشبكة العصبونية أفضل بكثير من النماذج الإحصائية والرياضية [6،7].

في هذا البحث استُخدمت الشبكات العصبونية الصناعية من أجل التنبؤ بقوة شد الليف القطني؛ وذلك بالاستناد إلى خصائص الليف الأخرى.

2. الشبكات العصبونية الصناعية Artificial (ANN) Neural Networks

A simple neural network
input layer hidden layer output layer

الشكل (1): بنية بسيطة لل ANN

هي نموذج حسابي مبني على خواص الشبكة العصبية الحيوية، ويتكون من وحدات مترابطة بعضها بعضاً بروابط اعتمادية. كما في الشكل (1). تقوم هذه الشبكات بمعالجة البيانات باستخدام مبدأ حساب يسمى بـ (Connectionist Approach) تعدُّ الشبكة العصبونية الصناعية نظاماً قابلاً للتكيف (adaptive system)، إذ تتغير بنيته اعتماداً على المعلومات التي تعبر من خلاله في ما يسمى بمرحلة التعلم. ويمكن الاستخدام العملي لهذه الشبكات في إمكانية تطبيق خوارزميات مصممة لتغيير وزن (أو قوة) الروابط التي تربط الخلايا العصبونية الصناعية ببعضها، لإنتاج سيل عصبي معين، فعل أو رد فعل [9].

فالشبكة العصبونية هي تجمع عدداً من العناصر الحسابية التي تُسمى نيورونات أو عقد. موزعة على التوازي ولها خاصية عصبية في تخزين المعلومات التجريبية وجعلها متاحة للاستخدام وهي تشبه الدماغ في أمرين [3]:

1- تكتسب المعلومات من خلال عملية التدريب.

- انحياز مطبق خارجياً (bias): هذا الانحياز يزيد أو يُقلل من الدخل الصافي لتابع التفعيل؛ وذلك بحسب قيمته التي يمكن أن تكون موجبة أو سالبة.

أي يمكن وصف النيورون رياضياً بالمعادلتين (1) و(2).

$$u_k = \sum_{j=1}^m W_{kj} \cdot x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

إذ:

x_1, x_2, \dots, x_m : إشارات الدخل

u_k : الخرج الخطي للجامع

$\varphi(-)$: تابع التفعيل.

$W_{k1}, W_{k2}, \dots, W_{km}$: الأوزان المشبكية للنيورون k.

b_k : الانحياز

y_k : إشارة الخرج للنيورون k

3. بناء الشبكة العصبونية الصناعية المطلوبة:

لبناء الشبكة العصبونية الصناعية المطلوبة يجب تنفيذ المهمات

الآتية:

1- تحديد مدخلات الشبكة العصبونية الصناعية ومخرجاتها.

2- إنشاء قاعدة بيانات

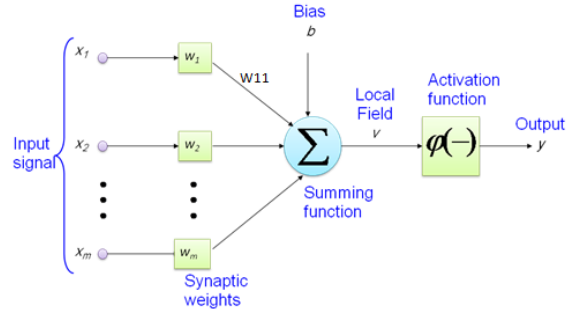
3- إنشاء الشبكة العصبونية الصناعية وتدريبها

1.3. تحديد مدخلات الشبكة العصبونية الصناعية ومخرجاتها:

من أجل بناء الشبكة العصبونية يجب تحديد معاملات الدخل والخرج التي ستستخدم لتدريب الشبكة المطلوبة. أنّ مدخلات الشبكة هي خواص ألياف القطن التي تؤثر في قوة شد الليف وهي: مؤشر الشعيرات القصيرة SFI، ونعومة الألياف MIC، وتناغم طول الألياف UNIFORMITY، وطول الألياف LENGTH، وعدد العقد NEPS، ونسبة الشوائب TRASH. تُحدّد المدخلات وفقاً لمصفوفة الدخل الموضحة بالمعادلة (1).

2- تخزين المعلومات باستخدام قوى وصل داخل العصبونات (neurons) تُسمى الأوزان المشبكية (Synaptic Weights).

وقد اقترح علماء الهندسة والحاسوب الشكل (2) كنظام يحاكي العملية الموجودة في الخلية العصبية الطبيعية [1]:



الشكل (2): تمثيل الشبكة العصبونية الصناعية

الهيكل المبين للعصبون الصناعي في الشكل (2) يتكون من:

- أشعة الدخل (Input Vector): تُمثّل بالعنصر (x_1, x_2, \dots, x_m)

- الأوزان (Weights): تُمثّل بالعنصر W_1, W_2, \dots, W_m وتحدد درجة الوزن للإشارة المدخلة. أي تعبر عن شدة الترابط بين عنصر قبله وعنصر بعده.

- عنصر المعالجة (Processing Element): وهذا العنصر يُقسم إلى قسمين:

- الجامع (Adder): لجمع الإشارات في الدخل الموزون.

- تابع التفعيل (Activation Function): هذا التابع يحدّد من خرج النيورون لذا يُسمى بتابع التخميد Squashing إذ يجعل الخرج ضمن مجال محدد غالباً يكون ضمن $[0, 1]$ أو $[-1, +1]$.

- أشعة الخرج (Output Vector)

2.3. إنشاء قاعدة بيانات:


أُجريت الاختبارات وجمعت البيانات في الشركة العامة للخياط القطنية (الساحل) - اللاذقية. حُددت خواص ألياف القطن المطلوبة لتدريب الشبكة العصبونية (ANN)، التي هي قوة شد الليف، وطول الألياف، ونعومتها، ومؤشر الشعيرات القصيرة، ودليل انتظامية طول الألياف حيث قيست هذه الخواص باستخدام جهاز ZELLWEGER -HVI 900. كذلك قيسَت نسبة الشوائب باستخدام جهاز USTER MDTA3، وعدد العقد (neps) باستخدام جهاز USTER AFIS. جمعت البيانات لـ 103 عينات وفقاً للمواصفة القياسية السورية للاعتيان: رقم /1495/، تاريخ /1995/ [2]. وأدرجت النتائج في الجدول (1).

$$\text{input ANN} = \begin{bmatrix} \text{NEP}_1 & \text{NEP}_2 & \dots & \text{NEP}_{1,3} \\ \text{TRA}_1 & \text{TRA}_2 & \dots & \text{TRA}_{1,3} \\ \text{FL}_1 & \text{FL}_2 & \dots & \text{FL}_{1,3} \\ \text{UI}_1 & \text{UI}_2 & \dots & \text{UI}_{1,3} \\ \text{MIC}_1 & \text{MIC}_2 & \dots & \text{MIC}_{1,3} \\ \text{SFI}_1 & \text{SFI}_2 & \dots & \text{SFI}_{1,3} \end{bmatrix} \quad (1)$$

بينما خرج الشبكة العصبونية هو قوة شد الليف القطني STRENGTH وهو الهدف المطلوب من الشبكة العصبونية. يُحدَّد وفقاً لمصفوفة الخرج الموضحة بالمعادلة (4).

$$\text{output ANN} = [\text{FS}_1, \text{FS}_2, \dots, \text{FS}_i, \dots, \text{FS}_{103}] \quad (4)$$

ومن ثمَّ يمكن تمثيل مخطط الشبكة العصبونية المطلوبة وفق الشكل (3)



الشكل (3): مخطط الشبكة العصبونية المطلوبة

الجدول (1): نتائج التجارب المستخدمة لتدريب الـ ANN

عدد العقد	نسبة الشوائب	طول الألياف	دليل انتظامية طول الألياف	نعومة الألياف	مؤشر الشعيرات القصيرة	قوة شد الليف
[nep/gram]	[%]	[inch]	[%]	[micronaire]	[%]	[gr]
174	3.28	1.21	82	5.1	3.9	33
164	3.51	1.22	84.1	4.9	3.5	33.9
182	2.92	1.2	83.4	5	3.7	32.3
143	3.29	1.21	85.2	5	3	33.2
178	3.57	1.21	83.8	4.9	3.5	33.1
160	3.21	1.17	84.1	5.1	4.1	29.7

158	3.5	1.23	86.8	5.1	2	33.6
164	4.08	1.18	86.8	4.8	2.8	32.1
127	4.29	1.17	83.7	5.2	3.9	29.9
153	2.81	1.16	84.8	4.9	3.4	31.4
163	3.34	1.22	84.8	5	3.2	31.9
157	3.18	1.17	85.4	4.9	3.5	32.9
183	2.49	1.21	84.9	4.9	3	31.5
144	2.74	1.17	83.2	5	3.8	31.1
155	3.21	1.18	83.7	5.1	3.5	31.2
171	2.74	1.19	83.5	5	4	31.9
185	2.14	1.13	80.9	5.2	5.8	29
223	1.93	1.19	81.3	4.9	4.5	29.7
192	1.89	1.14	81.9	4.9	5.4	29.7
219	2.44	1.2	81.9	5.1	4.5	30.9
194	2.23	1.21	82.7	5	3.9	30.5
194	3.14	1.17	85.9	5	3.1	31.3
174	2.47	1.16	84.3	5	3.9	31.3
125	2.78	1.19	85.4	5	3	33.2
171	2.28	1.2	86.5	4.8	2.7	33.8
158	2.79	1.19	83.6	5	4	31.9
210	2.6	1.18	81.4	5	4.4	32.9
212	2.9	1.22	83.5	5.1	3.5	33.1
202	3.7	1.22	83	4.9	2.8	32.4
207	1.8	1.2	84	5.1	3.1	31.4
187	1.96	1.12	82.1	5	5.2	31
235	1.31	1.19	81.5	5	4.3	31.8
233	2.13	1.17	82.2	4.9	4.3	33.1
234	2	1.13	83.8	5.1	3.9	31.4
202	1.87	1.15	82.5	4.9	4.8	31.3
223	1.16	1.18	83.8	5	4.4	32.6
191	2.51	1.15	84.2	4.8	3.5	29.5
194	3.33	1.16	84.4	4.8	3.4	30.1
179	2.46	1.15	81.8	5	4.6	28.6
192	3.67	1.15	81.4	4.9	5.5	29.3
185	2.71	1.18	83.9	5.2	3.6	28.8
185	3.51	1.14	82.3	5	3.9	27.4
209	1.97	1.17	82.9	4.9	4.3	34.6

185	1.57	1.17	84.3	5.1	3.4	30.4
187	1.92	1.22	82.3	5	3.8	33.9
173	1.96	1.18	83	4.9	3.6	29.8
208	1.82	1.2	82.7	5.2	3.6	33.5
196	1.67	1.2	81.6	5.1	4.2	33.2
147	3.05	1.28	85.3	4.6	2.4	37.1
146	3	1.24	83.3	4.8	2.9	34.6
132	2.91	1.27	86.7	4.6	1.6	38
155	2.6	1.23	87.3	4.8	2	36.7
158	3.01	1.23	74.8	5	2.8	34.3
165	2.8	1.25	86	4.9	2.3	36.2
132	3.45	1.23	86	4.9	2.3	34.2
186	4.28	1.21	85.6	5	2.9	33.8
207	3.66	1.22	83.4	4.9	3.2	34.8
221	1.56	1.19	81.1	5	3.8	30.3
195	1.79	1.14	80	5	5.9	31
199	1.78	1.13	79.9	5	7.3	29.6
186	3.05	1.24	86.5	4.8	2.3	34.3
224	2.02	1.15	81.8	5.1	4.9	29.7
215	2.51	1.17	82.2	4.9	4.3	31.2
201	2.57	1.18	84.2	5	3.6	31.9
192	2.86	1.23	84.7	5.1	2.7	34
199	2.33	1.26	82.9	4.7	3.5	34.4
186	1.71	1.22	82	5	3.9	33.7
189	2.75	1.18	83.1	5.1	3.6	32.2
193	1.98	1.18	81.2	5.2	4.8	30.9
203	1.7	1.16	83.5	5	3.9	32.4
242	1.46	1.14	83.9	5	4.5	32.4
238	2	1.16	81.6	4.8	4.2	33
249	1.88	1.18	82.2	4.8	4.2	33.6
244	2.48	1.16	83.9	5	3.8	32.7
251	2.62	1.18	81.4	4.8	4.9	31.6
228	2.76	1.18	81.5	4.9	4.5	31.9
266	3.15	1.14	82.6	4.9	4.5	32.3
265	2.14	1.16	81.2	4.9	5.3	31.9
249	2.58	1.14	81.7	4.8	5.3	32.4
181	3.2	1.17	81.4	4.8	4.2	32.7

265	2.66	1.15	81.7	5	4.8	31.9
226	2.11	1.18	81.8	4.6	4.5	33.5
270	2.6	1.17	82.7	4.8	4.7	32
199	2	1.28	81.5	5.1	3.3	34.1
230	1.91	1.18	83.3	5.1	4	33
190	2.6	1.25	83.1	5	3	35
214	2.53	1.19	82	5	3.7	32.5
214	2.66	1.17	83.2	4.5	4.2	33.2
230	2.6	1.2	82	4.6	3.8	33.7
205	2	1.14	80	4.8	5.7	29.7
212	2.31	1.13	81.2	5	5.5	30.5
227	2.8	1.14	83.6	5	4.4	31
229	2.8	1.15	82.5	5	5.1	30.4
231	1.9	1.17	80.6	4.9	5.1	29.8
199	2.32	1.2	81.1	5	4.6	32.2
171	2.69	1.17	81.6	4.8	4.5	30.9
145	2.86	1.21	82.6	4.6	3.8	32.7
151	1.76	1.19	86.3	5.1	2.9	33.1
177	2.54	1.24	86.6	4.8	2.6	35
161	1.96	1.21	84.7	4.8	2.6	32.9
161	2.89	1.2	83	4.8	3.4	33.1
212	1.81	1.19	81.3	4.8	4.6	32
219	2.01	1.22	82.3	4.6	3.6	35.2

3.3. بناء الشبكة العصبونية الصناعية وتدريبها:

مصفوفة أشعة الخرج للشبكة: وهي المصفوفة الهدف وتمثل قوة شدّ الليف القطني. حُدِّدَت بالمعادلة (2) وبيانات هذا لمصفوفة موضحة في الجدول (2).

epoch: مُعامل لإيقاف عملية التدريب، إذ تتوقف الشبكة عن التدريب إذا بلغ عدد التكرارات عدد الـ epoch المحدد.

Goal: لتحديد قيمة الخطأ الأصغري MSE.

min_grad: الميل الأصغري الذي يقف عنده التدريب.

يجب التنويه إلى أنّ $\text{min_grad} - \text{Goal} - \text{epoch}$: تُحدَّد تلقائياً ضمن بيئة الماتلاب.


يُقسم العمل في الشبكات العصبونية الصناعية ضمن بيئة الماتلاب إلى ثلاثة أطوار هي [1]:

يُنْبِئَتِ الشبكة العصبونية الصناعية باستخدام أداة الشبكات العصبونية (Artificial Neural Network Tool) الموجودة في بيئة الماتلاب (MATLAB®). تعتمد طرائق إنشاء الشبكات العصبونية في بيئة الماتلاب جميعها على تحديد عوامل أساسية هي:

مصفوفة أشعة دخل الشبكة: وهي مصفوفة خصائص ألياف القطن (طول، نعومة، وتناغم طول الألياف، ومؤشر الألياف القصيرة، ونسبة الشوائب، وعدد العقد). هذه المصفوفة حُدِّدَت بالمعادلة (1) وبيانات هذه المصفوفة موضحة في الجدول (1).


للعصبونات المخفية، وتابع تفعيل linear لعصبونات الخرج. لتدريب الشبكة تستخدم هذه الأداة خوارزمية التدريب Levenberg-Marquardt backpropagation algorithm (trainlm). وفي حال عدم توافر ذاكرة كافية تُستخدَم خوارزمية التدريب scaled conjugate gradient backpropagation (trainscg)[4].

تُستدعى هذه الأداة عند كتابة الأمر nftool في بيئة الماتلاب، حُدِّت مصفوفة الدخل للشبكة وحُدِّت مصفوفة الخرج (الهدف)، التي ذُكرت في الجدول (1). اختبرت نسبة الأشعة المطلوبة لعملية التدريب (Training) وهو 70%، ونسبة الأشعة المطلوبة لعملية التعميم (Validation) وهو 15%، ونسبة الأشعة المطلوبة لعملية الاختبار (Testing) وهو 15%. والشكل (4) يوضح نسب هذه الأشعة وعدد النماذج لكل عملية.



الشكل (4): نسب أشعة الدخل

اختبرت 4 عصبونات في الطبقة المخفية. كما يوضح الشكل (3).



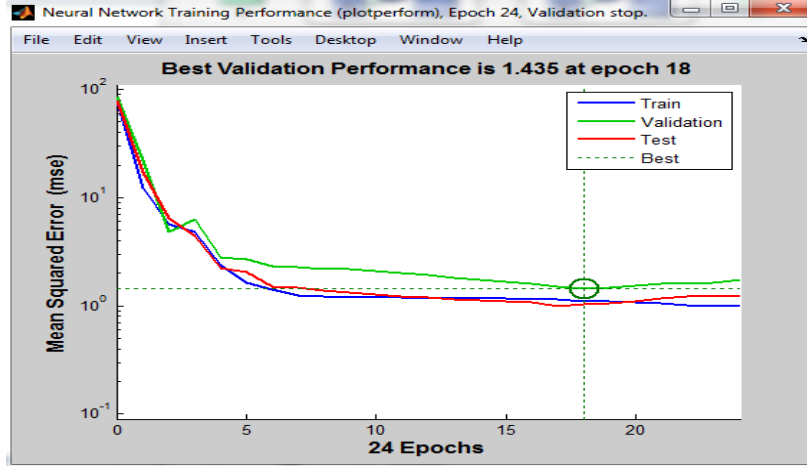
الشكل (5): المخطط الصندوقي للشبكة المطلوبة

دُرِّبَت الشبكة عدّة مرات حتى الحصول على نتائج مقبول وبنسبة خطأ أصغر ما يمكن. والشكل (4) يوضح النتائج.

	Samples	MSE	R
Training:	73	1.10899e-0	8.36529e-1
Validation:	15	1.43502e-0	7.41807e-1
Testing:	15	1.02901e-0	8.04935e-1

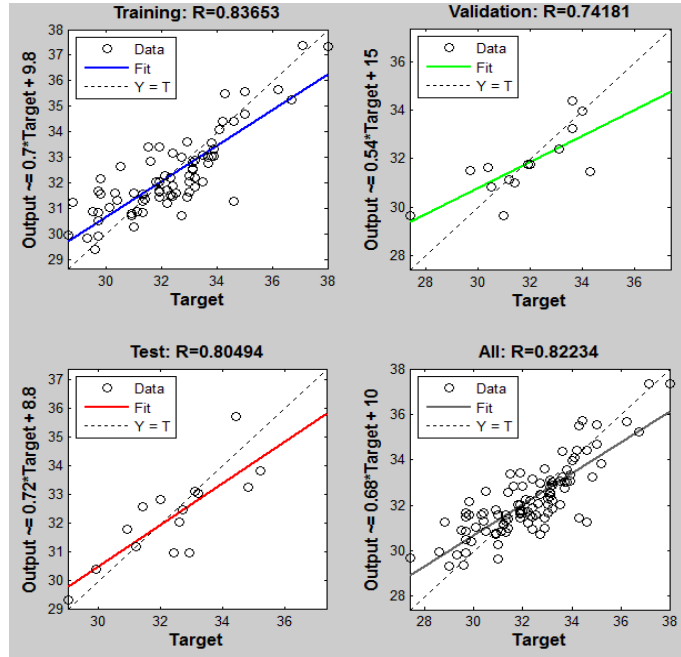
الشكل (6): النتائج النهائية لعملية التدريب

رُسمت المخططات البيانية التي تُظهر عملية تدريب الشبكة للوصول إلى أفضل النتائج، التي تظهر بالشكل (5).

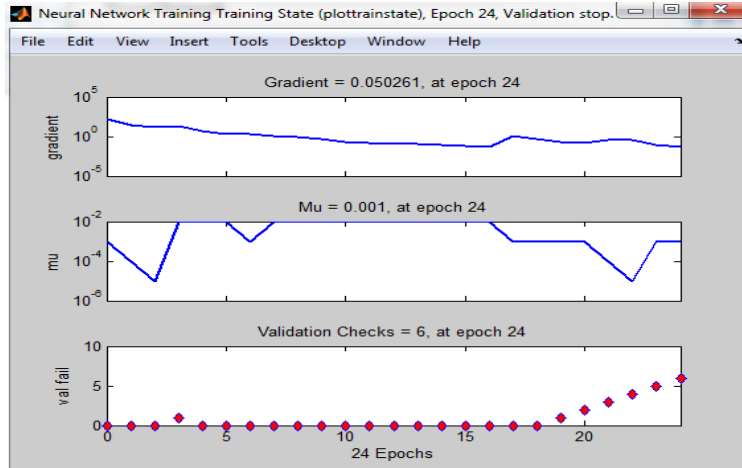


الشكل (7): المنحنيات البيانية الخاصة بعملية تدريب الشبكة

من الشكل (7) يُلاحظ أن عدد الـ Epochs و MSE تُحدَّد تدريب لها عندما تكون: $R=1$. رُسمت منحنيات الانحدار تلقائياً في بيئة الـ MATLAB. رُسمت منحنيات الانحدار الخطي لكل من عملية التدريب والتعميم والاختبار. الشكل (6) يوضح هذه المنحنيات. علماً بأن الشبكة تكون بأفضل

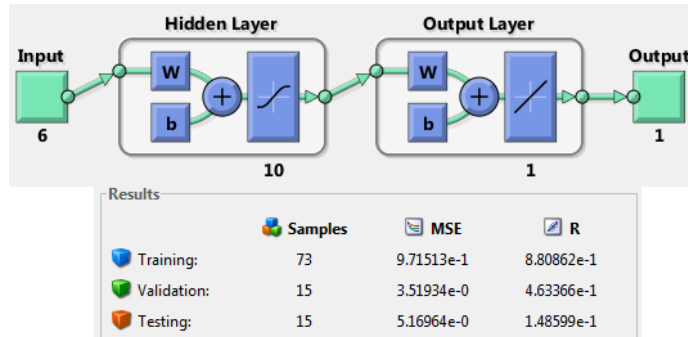


الشكل (8): منحنيات الانحدار الخطي الخاصة بالشبكة

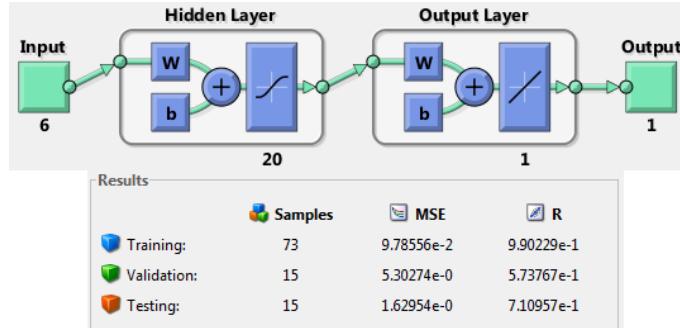


الشكل (9): نتيجة التدريب ونسبة الخطأ في الشبكة المختارة

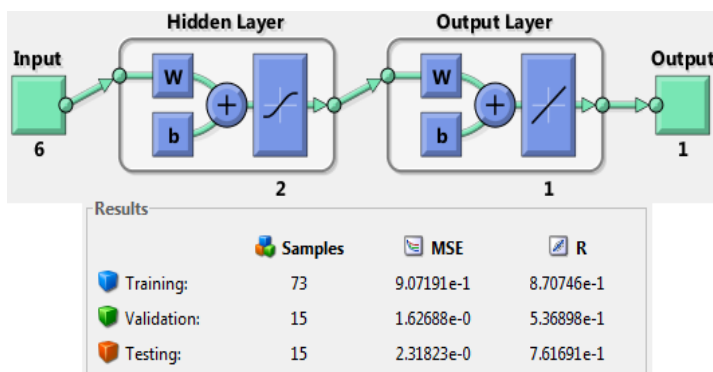
لوحظ عند بناء العديد من الشبكات العصبونية أنه عند زيادة عدد العصبونات إلى (10) عصبونات في الطبقة المخفية فإن نسبة الخطأ تزداد ازدياداً كبيراً، كما يوضّح الشكل (8). عند زيادة عدد العصبونات إلى (20) عصبوناً في الطبقة المخفية لوحظت زيادة الخطأ ازدياداً كبيراً. كما يوضّح الشكل (11). عند إنقاص عدد العصبونات إلى (2) عصبون لوحظ أن نسبة الخطأ تزداد أيضاً. كما يوضّح الشكل (12).



الشكل (10): أداء الشبكة عند زيادة عصبونات الطبقة المخفية إلى (10)



الشكل (11): أداء الشبكة عند زيادة عصبونات الطبقة المخفية إلى أكثر من (10)



الشكل (12): أداء الشبكة عند إنقاص عصبونات الطبقة المخفية إلى أقل من (4)

بواسطة الشبكة العصبونية الصناعية، وكذلك قيمة قوة شد الليف المخبرية (الفعلية).

القيمة المتوقعة للخيوط $[FS_{predicted}]$ تُورنت بالقيمة الفعلية المخبرية $[FS_{real}]$ ليتم التأكد من وثوقية التوقع. وقُيِّمت المقارنة كنسبة مئوية بواسطة المعامل المعرف بـ $\eta\%$ والذي يدعى (خطأ التنبؤ) ويُعطى بالعلاقة (3) [6].

$$\eta\% = \frac{|FS_{real} - FS_{predicted}|}{YS_{real}} \times 100 \quad (3)$$

فكلما كانت قيمة η صغيرة كانت عملية التنبؤ أفضل.

برسم المنحنيات البيانية الممثلة لكل من أداء الشبكة العصبونية والنتائج التجارب المخبرية يتم الحصول على الشكل (11).

مما سبق ينتج أن أفضل أداء للشبكة هي الشبكة الموضحة بالشكل (6) المبنية بعدد عصبونات في الطبقة المخفية يساوي (4) عصبونات. هذه الشبكة أعطت أقل نسبة خطأ في خرج الشبكة بالمقارنة بأداء الشبكات الأخرى، وكانت نسبة الخطأ الداخلي لتدريب الشبكة 1.1%، في حين كانت للتعيم 1.4%.


4. اختبار أداء الشبكة:

للتأكد من أداء الشبكة العصبونية الصناعية الناتجة، كان لا بد من إجراء مقارنة بين خرج الشبكة (الذي يمثل قيمة قوة شد الليف المتوقعة) وبين القيمة المخبرية الفعلية لقوة شد الليف.

يبين الجدول (2) نتائج اختبار (10) عينات جديدة لم تتدرب عليها الشبكة العصبونية بشكل مسبق. وأدرجت نتائج التنبؤ

الجدول (2): نتائج اختبارات المقارنة بين أداء الـ ANN والنتائج المخبرية

نسبة الخطأ (η)	قوة شد الليف المخبرية $[g_f]$	قوة شد الليف المتوقعة $[g_f]$	مؤشر الشعيرات القصيرة [%]	نعمرة الألياف [micronaire]	دليل انتظامية الأطوال [%]	طول الألياف [inch]	نسبة الشوائب [%]	عدد العقد [nep/gram]	تسلسل الاختبار
0.64776	33.5	33.7170	4	4.5	82.7	1.21	1.59	227	1
2.319938	32.1	31.3553	4.3	4.7	82.7	1.17	2.06	194	2
0.09519	31.2	31.2297	4.6	4.9	80.3	1.19	2.04	161	3
0.600316	31.6	31.4103	4.8	5	79.7	1.2	1.88	179	4
4.88483	32.3	33.8778	3.2	5	83.2	1.23	1.8	185	5
4.282036	33.4	31.9698	3.8	4.5	83.4	1.18	3.44	189	6
1.935312	33.7	33.0478	4	4.5	81.3	1.22	4	159	7
0.34415	34.2	34.3177	3.1	4.6	84.1	1.23	3.8	170	8
0.86836	35.4	35.7074	2.5	4.8	85.4	1.25	2.4	152	9
1.902744	32.8	32.1759	4.4	4.6	81.1	1.2	3.26	214	10



الشكل (11): مقارنة أداء الشبكة ANN من القيم المخبرية

5. مناقشة النتائج:

- 1) حققت الشبكة العصبونية الصناعية (ANN) نتائج أفضل من الأساليب التقليدية في التنبؤ بقوة شد الليف.
- 2) كلما زادت البيانات المستخدمة في إنشاء الشبكة العصبونية الصناعية (ANN)، كان أداء الشبكة أفضل.
- 3) التكاليف المباشرة للبحث تكاد تكون معدومة، على اعتبار أنّ اختبارات الألياف والخيوط هي من الأعمال الدورية في أي مخبر ضمن معمل الغزل.
- 4) لوحظ أن عدد العصبونات في الطبقة المخفية يؤدي دوراً أساسياً في عدد دورات تدريب الشبكة ودقة التنبؤ. اختبرت (4) عصبونات في الطبقة المخفية بما يحقق أقل قيمة خطأ في خرج الشبكة.
- 5) لوحظ أن نسبة الخطأ الداخلي لتدريب الشبكة العصبونية 1.1% وذلك عند epoch=18. في حين كان الخطأ الداخلي للتعميم 1.4%، الذي يظهر بدوره دقة أداء الشبكة.
- 6) إنّ الخطأ الخارجي الملاحظ عند اختبار الشبكة العصبونية على عينات جديدة لم تتدرب عليها مسبقاً كان نحو 4%.

6. التوصيات والمقترحات:

- 1) الاستفادة من الشبكة العصبونية الناتجة من هذا البحث كمؤشر لتقييم جودة الليف القطني باعتبار أن قوة شد الليف متحول مهم لمعرفة خواص ألياف القطن الأخرى.
- 2) عملية التنبؤ بقوة شد الليف تعطي إمكانية لمعرفة سلوك الخيط قبل إنتاجه بشكل فعلي؛ ممّا يوفر الوقت في إنتاجه، وكذلك في كلفة إنتاجه. مع ملاحظة أن قوة شد الليف تؤثر تأثيراً كبيراً في جودة الخيط المنتج.
- 3) العمل على تحسين أداء الشبكة العصبونية الصناعية. وذلك من خلال الزيادة المستمرة لعدد البيانات المستخدمة في تدريب الشبكة، كلما تسنت فرصة القيام بهذا العمل.
- 4) ضرورة القيام بمزيد من البحوث والدراسات التي تتناول موضوع الشبكات العصبونية الصناعية في مجال هندسة الصناعات النسيجية.

جدول الاختصارات		
الاختصار	المصطلح الإنكليزي	المصطلح العربي
ANN	Artificial Neural Networks	الشبكات العصبونية الصناعية
FS	Fiber Strength	قوة شد الليف
SFI	Short Fiber Index	مؤشر الشعيرات القصيرة
MIC	Fiber Fineness	نعومة الألياف
UI	Uniformity Index	دليل انتظامية الأطوال
FL	Fiber Length	طول الألياف
TRA	TRASH	نسبة الشوائب
NEP	NEPS	عدد العقد
% η	Prediction Error percentage	نسبة خطأ التنبؤ

7. المراجع*
- [1] أحمد، غاندي. *تطبيق الذكاء الصناعي للتنبؤ بقوة شد الخيوط القطنية* (2014)، جامعة دمشق، أطروحة ماجستير، عدد الصفحات: 116.
- [2] الألياف النسيجية- مواصفة بعض طرائق الاعتيان من أجل الاختبار: رقم /1495/، تاريخ /1995/. هيئة المواصفات والمقاييس العربية السورية.
- [3] كرمو، أحمد. (2001). *الشبكات العصبونية الصناعية بين النظرية والتطبيق (الجزء الأول)*. المركز العربي للتعريب والترجمة والتأليف. عدد الصفحات: 424 صفحة.
- [4] Demuth. H, Beale. M, (2000) "*Neural Networks Toolbox for Use with MATLAB*", The Math Works, Inc. Sixth printing Version 4 (2000), pp: 846.
- [5] Ethridge, M. D., Towery, J.D., and Hembree, J. F., '*Estimating Functional Relationship between Fiber Properties and The Strength of Open- End Spun Yarns*,' Text. Res. J., 35- 44, 1982.
- [6] Furferi. R, Gelli. M, (2010) "*Yarn Strength Prediction: A Practical Model Based on Artificial Neural Networks*", Hindawi Publishing Corporation, vol. 2010 ,11 pages.
- [7] Ghanmi. H, Ghith. A, And T. Benameur (2014), "*Application of Artificial Neural Network in Textile: Predication of Ring Spun Yarn Properties*", IOSR Journal of Engineering (IOSRJEN), pp: 7.
- [8] Hafez, O. M. A., '*Yarn Strength Prediction of American Cotton*,' Textile Res. J. 68, 701- 705, 1978.
- [9] Haykin. S, (1999) "*Neural Networks A Comprehensive Foundation*", Pearson Education, Inc. Second Edition, Ninth Indian Reprint (2005), pp: 823.
- [10] Lyengar, R. L. N., and Gupta, A. K., '*Proportion of Fiber Strength Utilized in the Single Yarn*,' Text. Res. J., 489- 492, 1974.
- [11] Lyengar, R. L. N., and Gupta, A. K., '*Some Functions Involving Fiber Properties for Estimating Yarn Tenacity*,' Text. Res. J., 492- 494, 1974.
- [12] Pan, N., '*Development of a Constitutive Theory for Short Fiber Yarns, Part I: Mechanics of Staple Yarn Without Slippage Effect*,' Text. Res. J. 62, 749- 765. 1992.