



الجمهورية العربية السورية

جامعة دمشق

كلية الهندسة الميكانيكية والكهربائية

قسم هندسة التصميم الميكانيكي

تحسين نعومة السطح في عمليات الخراطة باستخدام الشبكات العصبونية

والخوارزميات الجينية

رسالة مقدمة لنيل درجة الماجستير في هندسة أتمتة الإنتاج

إعداد

المهندس أحمد العبدلحي

المشرف العلمي

أ.د. محمد نادر زيدان

المشرف المشارك

د. رؤوف حمدان

العام الدراسي

2022-2023

قرار لجنة الحكم

بناء على قرار مجلس البحث العلمي والدراسات العليا رقم /5045/ المتخذ بالجلسة رقم /21/ تاريخ 2023/7/24 القاضي بتأليف لجنة الحكم على رسالة الماجستير التي أعدها الطالب: احمد خالد العبدلحي من السادة الأساتذة:

الاسم	الصفة	التوقيع
أ.د. محمد نادر زيدان	عضواً ومشرفاً	
أ.م.د. خالد شرف	عضواً	
د. محمد بسام أبو حرب	عضواً	

وقد تم إجراء التعديلات المطلوبة، وأصبحت الرسالة صالحة لمنح درجة الماجستير باختصاص هندسة أتمتة الإنتاج.

إهداء

أهدي تخرجي إلى من أعشقها إلى نبض قلبي إلى من تستقبلني بابتسامه وتودعني بدعوة "أمي الغالية" أسأل

الله أن يحفظها لي، وإلى سندي وحزام ظهري وأماني "أبي الغالي"، إلى من أعتمد عليه في كل كبيرة وصغيرة

أخي "عبدالحى"، إلى من أشعلوا شموع الأمل في لحظات مسيرتي المظلمة أخواتي "تور وآية وهبة".

كلمة شكر

نحمد الله عز وجل الذي وفقنا في إتمام هذا البحث العلمي، والذي ألهمنا الصحة والعافية والعزيمة فالحمد لله حمداً كثيراً.

❖ أتوجه بالشكر والامتنان للأستاذ الدكتور **"محمد نادر زيدان"** حفظه الله ورعاه وأطال في عمره الذي تفضل بقبول الإشراف على رسالة الماجستير والذي منحني من وقته الثمين ومن بحر معلوماته وخبراته الواسعة ماشكلاً إضافة كبيرة للعمل البحثي، إذ كانت توجيهاته ونصائحه المنارة التي استعنت بها في كامل عملي البحثي فأسأل الله عز وجل أن يجازيه خير الجزاء.

❖ أتقدم بالشكر للدكتور **"رؤوف حمدان"** من قسم هندسة الحواسيب والأتمتة لما قدمه من نصائح لإنجاز هذا البحث، متمنياً له دوام الصحة والعافية.

❖ أتقدم بالشكر لأعضاء لجنة المناقشة الكرام الدكتور **"خالد شرف"** والدكتور **"محمد بسام أبو حرب"** والدكتور **"محمد نادر زيدان"** على تفضلهم بقبول مناقشة رسالة الماجستير هذه.

❖ أتقدم بالشكر للمهندسة **"إيمان الشريحي"** التي ساهمت في إنجاز هذا البحث سواء بالمشورة أو التوجيه فلولا دعمها المتواصل وإرشاداتها القيّمة لما تمكنت من إنجاز هذا العمل بنجاح.

الفهرس

8	قائمة الأشكال
11	قائمة الجداول
12	قائمة الرموز والمصطلحات
14	الملخص
16	الفصل الأول: الإطار العام للرسالة
16	1.1 مقدمة
17	2.1 المشكلة العلمية للبحث
17	3.1 هدف البحث
18	4.1 أهمية البحث
18	5.1 الدراسات السابقة
22	الفصل الثاني: نظرية القطع
22	1.2 مقدمة
22	2.2 نظريات القطع
24	3.2 مواد أدوات القطع
27	4.2 أنواع الرايش
29	5.2 سوائل التبريد
30	6.2 تعريف عملية الخراطة
33	7.2 هندسة أداة القطع
35	8.2 ظروف القطع
38	9.2 الخلاصة
39	الفصل الثالث: خشونة السطح
39	1.3 مقدمة
39	2.3 المصطلحات التي تُستخدم لوصف السطح وتحديد جودته هي [5]:

3.3. تأثير زيادة خشونة السطح في الأجزاء	41
4.3. طرائق تقييم درجة نعومة السطح [5]	41
5.3. مقاييس الخشونة [5]	44
6.3. أجهزة قياس الخشونة [7]	47
6.3. الخلاصة	57
الفصل الرابع: الذكاء الصناعي	58
1.4. مقدمة	58
2.4. علم الآلة Machine Learning	58
1.2.4. أنواع علم الآلة	59
3.4. التعلم العميق Deep Learning	59
4.4. الشبكات العصبونية Neural Networks	61
1.4.4. العصبون Neuron	63
2.4.4. توابع التفعيل Activation Functions [16]	64
3.4.4. توابع الخسارة The Loss Functions [18]	66
4.4.4. توابع التحسين Optimizers	68
5.4.4. تطبيقات الشبكات العصبونية [18]	72
5.4. الخوارزميات الجينية Genetic algorithms	74
1.5.4. مقدمة	74
2.5.4. تعريف الخوارزميات الجينية (GA)	74
3.5.4. خطوات الخوارزميات الجينية [19]	75
4.5.4. أهم المصطلحات في الخوارزميات الجينية	76
1.4.5.4. الترميز	76
2.4.5.4. الاختيار Selection	78
3.4.5.4. التزاوج Crossover	79
5.5.4. اختلافات الخوارزميات الجينية عن خوارزميات الحل الأمثل التقليدية [21]	81
6.5.4. مزايا الخوارزميات الجينية وقيودها	82

83	7.5.4. تطبيقات الخوارزميات الجينية [21]
84	6.4. الانحدار الخطي
86	1.6.4. الفوائد الرئيسية للانحدار الخطي [24]
87	2.6.4. أنواع الانحدار الخطي
89	7.4. شجرة القرار Decision Tree
89	1.7.4. المصطلحات المستخدمة في شجرة القرار [11]
90	2.7.4. آلية عمل شجرة القرار
91	3.7.4. أنواع شجرة القرار
93	4.7.4. مميزات شجرة القرار [23]
95	8.4. الغابة العشوائية Random Forest
95	1.8.4. الفرق بين شجرة القرار والغابة العشوائية
96	2.8.4. أنواع الغابة العشوائية
99	3.8.4. مميزات خوارزمية الغابة العشوائية [26]
99	9.4. الخلاصة
100	الفصل الخامس: القسم العملي
100	1.5. مقدمة
100	2.5. تجهيز العينات
100	1.2.5. اختيار المعدن للتشغيل
101	2.2.5. اختيار اللقمة المستخدمة
101	3.2.5. اختيار البارامترات
104	4.2.5. رسم القطعة
104	5.2.5. استخراج G-code
105	6.2.5. تشغيل العينات على المخرطة
106	7.2.5. قياس خشونة العينات
109	3.5. دراسة تأثير بارامترات القطع في خشونة السطح
109	1.3.5. دراسة تأثير سرعة الدوران في خشونة السطح

110.....	2.3.5.دراسة تأثير عمق القطع في خشونة السطح.....
111.....	3.3.5.دراسة تأثير معدل التغذية في خشونة السطح.....
112.....	4.5. خوارزميات الذكاء الصنعي.....
114.....	1.4.5. خوارزميات التنبؤ.....
114.....	1.1.4.5. الانحدار الخطي.....
115.....	2.1.4.5. شجرة القرار.....
117.....	3.1.4.5. الغابة العشوائية.....
121.....	4.1.4.5. الشبكة العصبونية.....
125.....	5.1.4.5. الشبكة العصبونية المدربة بوساطة الخوارزمية الجينية.....
133.....	2.4.5. خوارزميات الحل الأمثل.....
133.....	1.2.4.5. الخوارزميات الجينية.....
141.....	الفصل السادس: النتائج والمناقشة.....
141.....	1.6. النتائج والمناقشة.....
148.....	الفصل السابع: التوصيات والآفاق المستقبلية.....
148.....	1.7. التوصيات.....
149.....	2.7. مقترحات لأعمال بحثية مستقبلية.....
150.....	الأعمال المرافقة للبحث.....
151.....	المراجع References.....
.....	الملاحق.....
.....	Abstract.....

قائمة الأشكال

- الشكل (1.2): مبدأ نظرية آرنست وميرشنت [1] 23
- الشكل (2.2): أنواع الرايش [1] 28
- الشكل (3.2): عمليات الخراطة [1] 31
- الشكل (4.2): العمليات التي يمكن إنجازها على المخرطة [1] 32
- الشكل (5.2): مصطلحات أداة القطع المستخدمة في الخراطة [4] 35
- الشكل (1.3): مصطلحات خشونة السطح [6] 40
- الشكل (2.3): تأثير بنية السطوح في مساحة التلامس [5] 43
- الشكل (3.3): طريقة النقاط العشرة للتعرجات [5] 43
- الشكل (4.3): مقياس عمق الخشونة [5] 44
- الشكل (5.3): عمق الخشونة R_t ، عمق التسطيح R_p [5] 45
- الشكل (6.3): متوسط أقصى انحرافات السطح R_z [5] 46
- الشكل (7.3): جهاز الاستشعار لقياس الخشونة [7] 48
- الشكل (8.3): مقياس خشونة توميلنسون [7] 49
- الشكل (9.3): تأثير حجم إبرة الاستشعار في دقة القياس [6] 50
- الشكل (10.3): تأثير حمل الاستشعار [6] 51
- الشكل (11.3): a - الانعكاس المرآوي b - الانعكاس الانتشاري c - الانعكاس المرآوي والانتشاري [6] 52
- الشكل (12.3): مبدأ عمل مجهر المقطع - الضوئي [6] 52
- الشكل (13.3): جهاز القطاع الجانبي البصري طويل المسار [6] 53
- الشكل (14.3): a - أسلوب الارتفاع الثابت b - أسلوب التيار الثابت [6] 55
- الشكل (15.3): مبدأ عمل جهاز (AFM) [6] 57
- الشكل (1.4): العلاقة بين الذكاء الصناعي وعلم الآلة والتعلم العميق [15] 60
- الشكل (2.4): زيادة دقة النموذج في التعلم العميق بزيادة حجم البيانات [16] 61
- الشكل (3.4): الشبكة العصبونية [16] 62
- الشكل (4.4): المدخلات مع الأوزان الموافقة لها [16] 63
- الشكل (5.4): تابع sigmoid [16] 64
- الشكل (6.4): تابع Relu [16] 65
- الشكل (7.4): توابع التفعيل المستخدمة في الشبكات العصبونية [17] 66
- الشكل (8.4): كيفية تعديل الأوزان حتى الوصول إلى أقل خطأ [17] 69
- الشكل (9.4): الفرق بين معدل التعلم المنخفض والمرتفع [17] 71
- الشكل (10.4): خطوات الخوارزمية الجينية [19] 76

- الشكل (11.4): الترميز الثنائي [19]..... 77
- الشكل (12.4): الترميز الثماني [19]..... 77
- الشكل (13.4): ترميز الرقم الحقيقي [19]..... 78
- الشكل (14.4): ترميز القيمة [19]..... 78
- الشكل (15.4): الاختيار عن طريق عجلة الروليت [20]..... 79
- الشكل (16.4): التزاوج في نقطة واحدة [20]..... 80
- الشكل (17.4): التزاوج في نقطتين [20]..... 81
- الشكل (18.4): العلاقة الخطية بين المتغير المستقل والمتغير التابع [24]..... 84
- الشكل (19.4): المستقيمات التي تربط بين المتغير المستقل والمتغير التابع [24]..... 85
- الشكل (20.4): المصطلحات الخاصة بشجرة القرار [23]..... 90
- الشكل (21.4): شجرة التصنيف [23]..... 92
- الشكل (22.4): شجرة الانحدار [23]..... 93
- الشكل (23.4): الغابة العشوائية للتصنيف [25]..... 97
- الشكل (24.4): الغابة العشوائية للانحدار [25]..... 98
- الشكل (1.5): اللقمة المستخدمة..... 101
- الشكل (2.5): رسم القطعة على برنامج solidworks..... 104
- الشكل (3.5): إجراء عملية الخراطة على برنامج Vero Surfcam..... 104
- الشكل (4.5): المخرطة المستخدمة..... 105
- الشكل (5.5): المخرطة مع توضع العينة..... 105
- الشكل (6.5): العينات بعد إجراء عملية الخراطة..... 106
- الشكل (7.5): جهاز قياس خشونة..... 107
- الشكل (8.5): العلاقة بين سرعة الدوران وخشونة السطح..... 109
- الشكل (9.5): العلاقة بين عمق القطع وخشونة السطح..... 110
- الشكل (10.5): العلاقة بين معدل التغذية وخشونة السطح..... 111
- الشكل (11.5): برنامج Pycharm..... 112
- الشكل (12.5): خوارزميات الذكاء الصناعي..... 113
- الشكل (13.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الانحدار الخطي..... 114
- الشكل (14.5): هيكل شجرة القرار..... 116
- الشكل (15.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام شجرة القرار..... 117
- الشكل (16.5): الشجرة الأولى..... 119
- الشكل (17.5): الشجرة الثانية..... 120
- الشكل (18.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الغابة العشوائية..... 121

- الشكل (19.5): الشبكة العصبونية المستخدمة 123
- الشكل (20.5): العلاقة بين عدد مرات التكرار والخطأ 124
- الشكل (21.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الشبكة العصبونية 125
- الشكل (22.5): زيادة دقة النموذج بازدياد عدد الأجيال 128
- الشكل (23.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية 129
- الشكل (24.5): الفرق بين الشبكة العصبونية والشبكة العصبونية المدربة بواسطة الخوارزميات الجينية 130
- الشكل (25.5): الفرق بين الشبكة العصبونية والشبكة العصبونية المدربة بواسطة الخوارزميات الجينية 131
- الشكل (26.5): العلاقة بين عدد الأجيال وكفاءة النموذج 135
- الشكل (27.5): العلاقة بين عدد الأجيال وكفاءة النموذج 137
- الشكل (28.5): العلاقة بين عدد الأجيال وكفاءة النموذج 138

قائمة الجداول

100.....	الجدول (1.5): التركيب الكيميائي للمعدن.....
101.....	الجدول (2.5): خصائص المعدن.....
102.....	الجدول (3.5): بارامترات القطع.....
103.....	الجدول (4.5): بارامترات القطع الموافقة لكل عينة.....
108.....	الجدول (5.5): نتائج قياس خشونة السطح للعينات.....
132.....	الجدول (6.5): أفضل خوارزمية للتنبؤ بخشونة السطح.....
140.....	الجدول (7.5): البارامترات المثلى لتحسين نعومة السطح.....

قائمة الرموز والمصطلحات

AI	الذكاء الصُّنعي
ML	علم الآلة
DL	التعلُّم العميق
ANN	الشبكات العصبونية
GA	الخوارزمية الجينية
ANN-GA	الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية
MSE	متوسط الخطأ التربيعي
SGD	الانحدار التدريجي
Turning	الخراطة
Surface roughness	خشونة السطح
Artificial Intelligence	الذكاء الصُّنعي
Linear regression	الانحدار الخطي
Decision tree	شجرة القرار
Random forest	الغابة العشوائية
Neural networks	الشبكات العصبونية
Activation function	تابع التفعيل
Loss function	تابع الخسارة
Genetic algorithm	الخوارزمية الجينية

Selection	الاختيار
Crossover	التزاوج
Mutation	الطفرة

الملخص

نعومة السطح هي من أهم الخصائص التي يجب أن تتوفر في المنتجات، إذ إن كثيراً من التطبيقات العملية تحتاج إلى سطح على درجة عالية من النعومة حتى تؤدي الوظيفة المطلوبة منها بأفضل أداء ممكن. تجدر أهمية خشونة السطح في أنها مؤشر أساسي لقياس جودة المواد، وفي عمليات التصنيع والإنتاج من المهم للغاية ولكنه من الصعب معرفة خشونة السطح بالاعتماد على المدخلات (سرعة الدوران، معدل التغذية، عمق القطع). وقد أشارت بعض الدراسات إلى أنه بزيادة سرعة الدوران أو بنقصان عمق القطع يتم تحسين خشونة السطح ولذلك أُجريت هذه الدراسة لمعرفة تأثير بارامترات القطع (سرعة الدوران، معدل التغذية، عمق القطع) في خشونة السطح لمعدن AISI 1040، وقد اختير هذا المعدن لما له من استخدامات مهمة وعديدة في الصناعة من أهمها: الوصلات، المحامل، عمود المرفق (الكرنك) وغيرها، ولُوحظ أن معدل التغذية فقط بنقصانه نقل خشونة السطح، في حين سرعة الدوران وعمق القطع لا يمكن معرفة قيمها المثلى لتقليل خشونة السطح، ولذلك استُخدمت خوارزميات الذكاء الصنعي (الشبكات العصبونية، الانحدار الخطي، شجرة القرار، الغابة العشوائية) وأُجريت مقارنة بينها لتحديد أفضل نموذج قادر على التنبؤ بخشونة السطح قبل إجراء عمليات التشغيل، ولُوحظ أن أداء الشبكات العصبونية هو الأفضل مقارنة مع الانحدار الخطي وشجرة القرار والغابة العشوائية. ثم استُخدمت الخوارزميات الجينية في عملية تدريب الشبكة العصبونية، وقد بيّنت النتائج أن الشبكة العصبونية المدربة بوساطة الخوارزمية الجينية أفضل من الشبكة العصبونية السابقة. ولإيجاد البارامترات المثلى لتحسين نعومة السطح استُخدمت الخوارزميات الجينية، وقُيِّمت الخوارزميات الجينية عن طريق استخدام البارامترات الناتجة عن الخوارزميات الجينية بتشغيل عينات عدة جديدة، وأظهرت النتائج أن الخوارزميات الجينية أعطت نعومة سطح أفضل من العينات التجريبية.

الكلمات الرئيسية: الخراطة، خشونة السطح، الذكاء الصنعي، الشبكات العصبونية، الانحدار الخطي، شجرة

القرار، الغابة العشوائية، الخوارزميات الجينية.

تتضمن هذه الرسالة سبعة فصول إضافةً إلى قوائم المراجع العلمية والأشكال، وأخيراً ملحقاً يشتمل على الكودات البرمجية المكتوبة بلغة برمجة البايثون التي استخدمت في هذا البحث. يُقدّم الفصل الأول الإطار العام للرسالة (المقدمة، المشكلة العلمية للبحث، أهداف البحث، أهمية البحث) والدراسات السابقة المرتبطة بالمشكلة العلمية للبحث والتي تظهر أهمية توظيف الذكاء الصنّعي في الصناعة، في حين يتضمن الفصل الثاني نظرية القطع وعملية الخراطة، والفصل الثالث يحتوي على مفهوم خشونة السطح (تعريفها، طرق قياسها، وأجهزة قياس الخشونة...)، أما الفصل الرابع فيحتوي على الذكاء الصنّعي (تعريفه، علم الآلة، الشبكات العصبونية، الخوارزميات الجينية...). يُقدّم الفصل الخامس الجزء العملي اللازم لإجراء البحث (الأجهزة اللازمة لإجراء البحث، تشغيل العينات، قياس خشونة العينات، برمجة كل خوارزمية، مقارنة أداء الخوارزميات، الوصول إلى الحل الأمثل)، يُقدّم الفصل السادس النتائج من هذه الدراسة ومناقشة هذه النتائج وأخيراً يُقدّم الفصل السابع التوصيات التي نتجت من هذه الدراسة والمقترحات لأعمال مستقبلية.

الفصل الأول: الإطار العام للرسالة

1.1. مقدمة

لقد مرّت عمليات تصنيع المعادن وتشغيلها بمراحل كثيرة أسهمت في تطورها ومنذ نشوء الإنسان الأول إلى يومنا هذا، إذ بدأت مسيرة التطور من العصر الحجري وماشده من تصنيع الآلات مروراً بعصر اكتشاف المعادن وما تبعه من تطور للصناعات الحرفية وصولاً إلى عصر الثورة الصناعية وما نتج عنه من اكتشافات صناعية كبيرة إلى أن وصلت إلى المرحلة الراهنة وما نراه فيها من كثرة طرائق التصنيع وتنوعها والتي مازالت مستمرة في التطور ومن دون توقف [1]. إن من أهم الصناعات الحالية تشغيل الفولاذ كونه يؤدي دوراً مهماً في الصناعات الهندسية، وتتنافس الشركات مع بعضها بعضاً في الحصول على سعر منخفض مع جودة عالية في تشغيل الفولاذ، لأن جودة السطح هي واحدة من أهم خصائص المنتج في التصنيع، وهي واحدة من أكثر المتطلبات شيوعاً في التصنيع الآلي بسبب تأثيرها في أداء المنتج، وتؤثر خشونة السطح بشكل كبير في الأداء الوظيفي للأجزاء الميكانيكية مثل: مقاومة التآكل ومقاومة التعب وتوزيع سوائل التشحيم وتوليد الحرارة ونقلها وغيرها. في جميع الأنظمة الميكانيكية ليس فقط السلوك الميكانيكي للمواد مهماً، ولكن أيضاً استجابة الأجزاء والهياكل هي قضايا مهمة، وقد يحدث الفشل الميكانيكي لأسباب مختلفة عديدة منها زيادة التحميل والإجهاد والعيوب في المواد والتصميم الرديء وأيضاً زيادة خشونة السطح وهي من أهم العوامل المؤثرة في فشل الأجزاء الميكانيكية وهو ما تمّ التركيز عليه في هذا البحث. لذلك طُرح موضوع البحث الحالي الذي سعى إلى تطوير نظام قادر على زيادة دقة التنبؤ بخشونة السطح باستخدام خوارزميات الذكاء الصنعي، ثم إيجاد البارامترات المثلى والتي تعطي أفضل نعومة للسطح لتحسين عمل الأجزاء الميكانيكية.

2.1. المشكلة العلمية للبحث

في أثناء عمليات التشغيل تُعدُّ خشونة السطح عاملاً مهماً وأساسياً في تقييم جودة قطعة العمل والخشونة الزائدة سبب رئيسي لتشكيل الصدأ وضعف مقاومة القطعة ميكانيكياً. يوجد العديد من العوامل المؤثرة في خشونة السطح: عوامل غير خاضعة للتحكم مثل: تآكل الأدوات وأخطاء في حركة الآلة والاهتزاز وغيرها... وعوامل خاضعة للتحكم: سرعة الدوران، معدل التغذية، عمق القطع والتي يتم تحديدها عادةً بحسب المجال الواسع للشركة المُصنِّعة لأداة القطع وخبرة العامل، ومن الممكن أن يتم الاختيار الخاطئ لهذه العوامل ومن ثم يتم التخلص من المشغولة والذي يؤدي إلى زيادة في التكلفة والوقت والجهد. وقد تركزت أغلب الدراسات على استخدام الشبكات العصبونية في شتى المجالات ولاسيما في عملية التنبؤ بخشونة السطح، ومن السليبيات لاستخدام الشبكات العصبونية هو حاجتها إلى العديد من البارامترات التي يجب ضبطها والتي بدورها تستغرق كثيراً من الوقت. ومن هنا جاءت هذه الدراسة لبيان إمكانية استخدام خوارزميات الذكاء الصُّنعي الأخرى ومقارنتها مع أداء الشبكات العصبونية لتحديد أدق نموذج قادر على التنبؤ بخشونة السطح بوقت قياسي كونه يُطلب عادةً قيمة خشونة مُحدَّدة بحسب الوظيفة التكنولوجية للقطعة، وفي بعض الحالات من الضروري الحصول على نعومة سطح عالية جداً لذلك استُخدمت الخوارزميات الجينية وهي إحدى خوارزميات الذكاء الصُّنعي للحصول على الحل الأمثل.

3.1. هدف البحث

يمكن تلخيص أهداف هذا البحث إلى:

- التوسع في مجال الذكاء الصُّنعي لتحزِّي إمكانية استخدام خوارزميات أخرى للتنبؤ بخشونة السطح ومقارنتها مع بعضها بعضاً.
- استخدام نموذج هجين من الذكاء الصُّنعي لزيادة دقة التنبؤ بخشونة السطح.
- الوصول إلى البارامترات المثلى باستخدام الذكاء الصُّنعي والتي تؤدي إلى تحسين خشونة السطح.

4.1. أهمية البحث

عند الوصول إلى نموذج قادر على التنبؤ بخشونة السطح بدقة عالية جداً يؤدي إلى الاختيار الأمثل لبارامترات القطع (سرعة الدوران، معدل التغذية، عمق القطع) قبل إجراء عمليات التشغيل ومن ثم معرفة مسبقة بخشونة السطح والذي يؤدي بدوره إلى التخلص من عمليات التجريب وعند الحصول على نعومة سطح عالية سيؤدي إلى:

1. تقليل الاحتكاك بين السطوح المتحركة ومن ثم زيادة عمر القطعة المشغلة.
2. تحسين أداء أجزاء الآلات المعرضة للإجهادات المتغيرة، لأن مقاومة التعب تتأثر بدقة إنهاء السطح.
3. تقليل الذبذبات وانخفاضها في آلات التشغيل.

5.1. الدراسات السابقة

تشتمل هذه الفقرة على مجموعة من الأعمال البحثية التي قام بها مجموعة من الباحثين ضمن إطار تأثير بارامترات القطع في خشونة السطح واستخدامات الذكاء الصناعي.

- 1.5.1. قام الباحث [2] ببناء نموذج لشبكة عصبونية قادرة على التنبؤ بخشونة السطح قبل إجراء عمليات التشغيل لمعدن CK 60، ونموذج الشبكة العصبونية المستخدم يتألف من: طبقة مدخلات وتحتوي على بارامترات القطع: سرعة القطع، معدل التغذية وعمق القطع، في حين الطبقة المخفية تحتوي على 18 عصبون، وطبقة الخرج هي خشونة السطح، إذ قام الباحث بتشغيل 60 عينة لتدريب الشبكة العصبونية ثم اختُبر النموذج لبيان إمكانية استخدام هذا النموذج في المستقبل عن طريق حساب متوسط الخطأ التربيعي بين القيم الحقيقية والقيم المتنبأ بها وكانت قيمته $MSE = 6.37\%$.

- 2.5.1. قام الباحث [8] بدراسة تأثير سرعة القطع على كل من: خشونة السطح وتآكل أداة القطع في عملية الخراطة لمعدن AISI 1040، إذ استُخدم لقمة كربيدية من نوع TiAlN ceramic tungsten

carbide. وكانت نتيجة البحث أنه بتقليل سرعة القطع لاحظ الباحث تآكل أداة القطع بشكل كبير، في حين عند استخدام أقصى سرعة قطع لاحظ الباحث أنه تم تحسين نعومة السطح.

3.5.1. تركزت الدراسة [9] على مقارنة تأثير أدوات القطع من نوع PVD, CVD في خشونة السطح، إذ قام الباحث باستخدام طريقة تاجوشي لإيجاد التصميم الأمثل لتشغيل العينات لمعدن من نوع AISI 1040. كانت نتيجة البحث عند استخدام أداة قطع من نوع CVD أنّ خشونة السطح أفضل من استخدام PVD.

4.5.1. تناولت الدراسة [10] دراسة تأثير سرعة القطع، معدل التغذية وعمق القطع في كلٍ من: خشونة السطح وقوة القطع في تشغيل فولاذ طري، أما أداة القطع فهي من نوع الصلب ذي السرعات العالية HSS. وكانت نتيجة البحث: معدل التغذية له أكبر تأثير في كلٍ من: قوة القطع وخشونة السطح، في حين سرعة القطع ليس لها تأثير كبير على قوة القطع وخشونة السطح، أما عمق القطع فله تأثير كبير على قوة القطع في حين تأثيره في خشونة السطح هو قليل، ثم قام الباحث بإيجاد علاقة تربط بين بارامترات القطع في عملية التنبؤ بخشونة السطح.

5.5.1. في الدراسة [11] قام الباحث باستخدام إحدى خوارزميات الذكاء الصنعي وهي شجرة القرار في عملية التنبؤ بالطقس، إذ استُخدمت البيانات من عام: 2002-2005 في مدينة Hong Kong. أظهرت النتائج إمكانية التنبؤ بالطقس بشكل جيد باستخدام شجرة القرار.

6.5.1. تتركز الدراسة [12] على مقارنة 4 من أدوات الذكاء الصنعي وهي: الشبكات العصبونية، الشبكة البايزية، المنطق الضبابي، المنطق المعتمد على الحالة، في مجال كسر الأجزاء الميكانيكية وفشلها. إذ وضعت آلية الفشل واكتُشفت الأخطاء وشُخصت وحُدّدت بارامترات الكسر، ولاحظ الباحث أن الشبكات العصبونية

تعطي نتائج مثالية، والفشل الميكانيكي حُدِّد بوساطة الشبكات العصبونية والشبكة البايزية¹ وهذا النموذج أعطى نتائج ممتازة، وكذلك الأمر في المنطق الضبابي² إذ أعطى نتائج جيدة في عملية اكتشاف فشل الأجزاء الميكانيكية وتحديده. والمنطق المعتمد على الحالة³ استُخدم في تحديد آلية الفشل. ومن أجل استخدام نموذج هجين ذكي قام الباحث باستخدام المنطق المعتمد على الحالة مع الأدوات الأخرى، إذ دُمج المنطق المعتمد على الحالة مع الشبكة البايزية وتم التوصل إلى أن النموذج الهجين أفضل من استخدام الأداة لوحدها وتم توفير الوقت أيضاً في حالة استخدام النموذج الهجين.

7.5.1. تتناول الدراسة [13] طرائق التخطيط الأمثل لآليات الحركة للميكانيزمات ثنائية الأبعاد. اعتمد هذا البحث على الخوارزميات الجينية المستندة إلى تقنيات تطويرية. استُخدمت آليات التخطيط الأربعة الساكنة كاختبار للطريقة، وأظهرت النتائج أن الحلول دقيقة وصحيحة لجميع الحالات، وقد سُلط الضوء على إمكانية توسيع الطريقة إلى أنواع آليات أخرى. تتمثل المزايا الرئيسة للطريقة في بساطة تنفيذها وسرعة التقارب إلى الحل الأمثل دون الحاجة إلى معرفة عميقة لمساحة البحث.

8.5.1. الدراسة [14] تُطبق الخوارزميات الجينية (GA) على حل مشاكل تصميم الهياكل، ويقترح الباحث تصميم مادة وترميزها بشكل ثنائي. تهدف هذه الطريقة إلى تقريب توزيع المواد المستمر بدلاً من الهياكل المنفصلة. قام الباحث بتقديم أربعة أمثلة ليظهر فيها مدى تنوع الأسلوب والتمثيل المُقترح في حل مشاكل تصميم الهياكل، والمُقترح الخامس يُشير إلى تمثيل بديل يسمح بتوزيع كثافة المواد باستمرار.

ومن خلال الدراسات السابقة لُوحظ ما يأتي:

¹ نموذج حسابي يُستخدم في مجال الذكاء الصنعي لتمثيل العلاقات الاحتمالية وتحليلها بين المتغيرات. تعتمد على مبدأ التحديث المستمر للمعرفة.

² طريقة منطقية تشبه التفكير البشري وتعتمد على نمط منطقي يشمل جميع الاحتمالات الوسطية بين الصحيح والخطأ.

³ نمط من الذكاء الصنعي يعتمد على استخدام تجارب سابقة لاتخاذ قرارات في حل مشكلات جديدة.

1. يوجد العديد من العوامل المؤثرة في خشونة السطح ولكن أهمها هي: سرعة القطع، معدل التغذية، عمق القطع، وهذا ما يستدعي الحاجة إلى دراسة تأثير هذه البارامترات في خشونة السطح لكل معدن.
2. أهمية استخدام الذكاء الصنعي في مجال الميكانيك عامة وفي مجال التنبؤ بخشونة السطح خاصة.
3. أغلب الدراسات السابقة ركزت على استخدام الشبكات العصبونية دون غيرها والشبكات تتطلب كثيراً من البارامترات لضبط دقة التنبؤ والتي بدورها تستغرق كثيراً من الوقت لتحسين دقة التنبؤ كما في [2] وهذا يستدعي الحاجة إلى استخدام خوارزميات أخرى من الممكن أن تكون أفضل من الشبكات.
4. عند استخدام نموذج هجين من الذكاء الصنعي لوحظ زيادة دقة النموذج كما ذكر في [12] لذلك سيتم استخدام نموذج هجين من الذكاء الصنعي لزيادة دقة عملية التنبؤ بخشونة السطح.

الفصل الثاني: نظرية القطع

1.2. مقدمة

إن عملية إزالة المعدن تتم عن طريق تَعَشُّق أداة القطع مع المشغولة وتكون المادة المُزَالَة على شكل شظايا تُعرف بالرايش (Chip). إن عمليات قطع المعدن تعود إلى سنوات عديدة مضت ورغم تعدد التقنيات المستخدمة اليوم في الصناعة إلا أنَّ آلية تَكُون الرايش هي نفسها، فعندما تتغلغل أداة القطع (Cutting Tool) داخل المشغولة فإن المادة التي تقع أمام الأداة مباشرة سوف يتم قَصُّها وتتشوه تحت ضغط أداة القطع، وتبدأ المادة المشوهة بالتكسُّر نتيجة للإجهاد الناتج من عملية القطع، وتنساب فوق الأداة على شكل رايش [1].

2.2. نظريات القطع

إن عملية القطع وتكوين الرايش جرى تفسيرها بعدد من النظريات من أجل معرفة الآلية التي تتم فيها والظروف والعوامل التي تتحكم فيها، ومن أهم النظريات التي فسَّرت ذلك:

1.2.2. نظرية تريسيكا


وهي من أولى النظريات التي فسَّرت عملية القطع، إذ قام العالم تريسيكا في العام (1873) بتعريف عملية القطع على أنها عبارة عن ضغط يولده رأس الأداة عند تماسه مع المشغولة مصحوباً بجهد قص واقع في مستوى موازٍ لسطح المشغولة الذي ينتج عنه تكوين الرايش.

2.2.2. نظرية تيمي

وضَّح هذا العالم أن تكوين الرايش ينتج من تكسُّر المعدن على مستوى القص.

3.2.2. نظرية آرنست وميرشنت

وتُعدّ من أدق النظريات التي وضعت لتفسير كيفية قطع المعدن والشكل رقم (1.2) يوضح مبدأ هذه النظرية. تبدأ أداة القطع بالانسياب داخل المشغولة بعمق قطع (t_1) مولدة مستوى قص (AB) وهو النقطة التي يبدأ عندها القطع مولداً ريش ثخنه (t_2) وبزاوية قص مقدارها (ϕ) وبزاوية جرف (γ) وعند زاوية خلوص (α).



الشكل (1.2): مبدأ نظرية آرنست وميرشنت [1]

3.2. مواد أدوات القطع

هنالك العديد من مواد أدوات القطع المستخدمة اليوم في عمليات التشغيل والتي مرت بمراحل طويلة من التطور إلى أن وصلت إلى ما نشاهده حالياً من تنوع في المواد المستخدمة فيها. إن الاختلافات الموجودة بين مواد أدوات القطع أوجدت تنوعاً كبيراً في تطبيقات هذه الأدوات ومجالات استخدامها اعتماداً على المادة المصنوعة منها هذه الأدوات. إن الأداة المثالية ليست بالضرورة التي تكون أعلى كلفة أو أقل كلفة أو التي تُستخدم للعمل بشكل متكرر، وإنما الأداة المثالية هي التي يتم اختيارها بحرص لأداء العمل بسرعة وكفاءة واقتصادية. ويعتمد هذا الاختيار على طبيعة العمل الذي تقوم به أداة القطع وعلى نوع المادة المشغلة [3].

تعتمد طبيعة العمل الذي تقوم به الأداة على خواص الأداة الميكانيكية إضافة إلى نوع مادة الأداة، وأهم هذه الخواص هي:

1. القساوة: يجب أن تتمتع أداة القطع بقساوة عالية والتي تسمى بالقساوة الساخنة والتي تُمكنها من الاحتفاظ بمقاومتها في درجات الحرارة العالية.
2. المتانة يجب أن تكون متانة أداة القطع عالية حتى لا تتشظى أو تنكسر خصوصاً في أثناء عمليات التشغيل المتقطع.
3. مقاومة البلى العالية التي تزيد من عمرها.
4. مقاومة ضغط وحني عالية.
5. مقاومة عالية للتأكسد.
6. قابلية تشغيل عالية.

1.3.2. فولاذ العُد

يتكون فولاذ العُد من نوعين أساسيين هما:

(a) الفولاذ الكربوني وتتراوح نسبة الكربون فيه (0.2%-0.8%) ويُصَلد بتسخينه إلى درجة حرارة (750°C – 835°C) ثم يُبرّد سريعاً في الماء.

(b) الفولاذ منخفض السبائك ويحتوي هذا النوع من الفولاذ على عددٍ من العناصر مثل: التنتستين، المنغنيز، الكروم، الفاناديوم.

2.3.2. فولاذ السرعات العالية

إن هذا النوع من الفولاذ هو فولاذ عالي السبائك إذ يُضاف عددٌ من العناصر من أجل زيادة القساوة ومقاومة الفولاذ وجعله أكثر مقاومة للحرارة. إن العناصر التي تضاف إلى هذا النوع من الفولاذ هي التنتستين، المنغنيز، الكروم، الفاناديوم، الكوبالت، النيوبيوم [3]. إن الصفات التي يتم الحصول عليها من هذه العناصر تسمح باستخدام سرعات تشغيل أعلى مع تحسُّن الإنجاز السطحي مقارنة مع أدوات الفولاذ الكربوني.

3.3.2. الكرييدات المُسمنتة

يُستخدم في هذا النوع من المواد كربيد التنتستين، كربيد التيتانيوم في أرضية من الكوبالت. إن قساوة الكربيد هي أعلى من معظم مواد الأدوات الأخرى، وتمتلك هذه الأدوات القدرة على الاحتفاظ بقساوتها في درجات الحرارة العالية لفترات طويلة، وهذا يجعل التشغيل في السرعات العالية ناجح جداً.

4.3.2. الأدوات المطلية

إن أسلوب إكساء السطوح بطبقات قاسية لغرض تحسين أدائها هو أسلوب مُنبَع لتقليل التآكل والاحتكاك. هنالك طريقتان رئيستان تستخدمان في عملية الطلاء هي الترسيب الكيميائي للبَخار (CVD) والترسيب الفيزيائي للبَخار (PVD). إن طبقة الطلاء الرقيقة تكون عالية القساوة وذات درجة انصهار عالية وتبلغ ثخانة هذه الطبقة بحدود $4-7 \mu m$. إن من أكثر مواد الطلاء شيوعاً هي كربيد التيتانيوم، نتريد التيتانيوم، السيراميك، كربيد نتريد التيتانيوم، والألماس. إن الهدف من الطلاء هو:

1. تحسين الصفات الكيميائية لأدوات القطع بتقليل قابلية التصاق معدن المشغولة على سطح الأداة.
2. تحسين الصفات الفيزيائية لسطح أداة القطع يُخفف الاحتكاك بين سطح الأداة والمشغولة وهذا يؤدي إلى خفض درجة الحرارة المتولدة.
3. زيادة عمر الأداة وهذا يقلل المدة الزمنية اللازمة لتدخل العامل للسيطرة على عملية القطع.

5.3.2. الأدوات السيراميكية

تُصنَّع هذه الأدوات من أوكسيد الألمنيوم الذي يمتاز بمقاومة عالية للحرارة، وتمتاز الأدوات السيراميكية بقساوة ومقاومة ضغط عاليتين، ولكن متانتها ومقاومتها أقل من الأدوات الكريبدية.

6.3.2. الأدوات السرميتية

السرميت هو كلمة مشتقة من سيراميك ومعدن إذ يتم استخدام المواد السيراميكية مع المعادن مثل: كربيد التيتانيوم، النيكل، الكوبالت، نتريد التيتانيوم، وكربيدات أخرى. يمتلك السرميت قساوة عالية ومقاومة تأكسد أفضل من الكربيدات المسمنة، ومقارنة بالكربيد يُعدّ السرميت أقل متانة وأقل موصلية حرارية، وأعلى تمدد حراري [1].

7.3.2. أدوات الألماس

يستعمل الألماس بنوعيه الطبيعي والصناعي في أدوات القطع التي تعمل في سرعات عالية للإنهاء السطحي الدقيق مع مُعدل تغذية قليل جداً.

8.3.2. نتريد البورون

وهو يشبه الألماس من حيث التركيب يُستخدم نتريد البورون المكعب بفاعلية في تشغيل معظم المواد الهندسية وخصوصاً القاسية منها وصعبة التشغيل.

4.2. أنواع الرايش

إن عملية قطع المعدن تُنتج شظايا متطايرة تدعى بالرايش، ويقسم الرايش الناتج من عمليات القطع إلى:

1.4.2. الرايش غير المستمر أو المُتشظي

ينتج الرايش غير المستمر أو المتشظي عند قطع المعادن الهشة مثل حديد الزهر أو عندما يتم قطع معادن مطيلية تحت ظروف قطع رديئة.

ويكون الرايش غير المستمر على أنواع وهي:

- الرايش المتفتت
- الرايش المُنقطع
- الرايش الدقيق

يحصل الرايش غير المستمر نتيجة لسرعة القطع المنخفضة وزاوية الجرف الصغيرة، والشكل (a.2.2) يوضح هذا النوع من الرايش.

2.4.2. الرايش المستمر

ينتج الرايش المستمر عندما لا يُعاق جريان المعدن الأقرب إلى وجه الأداة بواسطة حافة القطع الناشئ أو الاحتكاك عند السطح البيني للأداة. ينتج الرايش المستمر في المعادن المطيلية إذ تكون سرعة القطع عالية إضافة إلى أن زاوية الجرف تكون كبيرة. يكون هذا النوع من الرايش بشكل شريط مستمر، ويوضح الشكل (b.2.2) هذا النوع من الرايش ويكون الرايش المستمر على أنواع هي:

- الرايش المستقيم

الرايش المستقيم هو الأكثر إزعاجاً من بين أنواع الرايش إذ يلتف الرايش على أداة القطع والمشغولة. هذا النوع من الرايش يتكوّن في المواد المطيلية مثل الفولاذ منخفض الكربون والألمنيوم.

- الرايش المتشاك


وهو رايش مستمر يشبه تقريباً الرايش المستقيم، ويتكوّن بالظروف نفسها التي يتكوّن فيها الرايش المستقيم ويُؤدّ المشاكل نفسها إلا أنه يكون ملتوي الشكل أو مُتشاكاً.

- الرايش الحلزوني

ويكون بشكل نابض حلزوني غير منتهي، إن المشاكل التي تتولد من هذا النوع من الرايش تشابه تلك المتولدة في حالة الرايش المستقيم. يتكوّن الرايش الحلزوني في المواد المطيلية اللاحديدية ويحصل هذا النوع من الرايش غالباً عندما يُستخدم قطع خفيف وللتخلص منه يُنْبَع الآتي:

- استخدام لقمة تحتوي على كسّارة رايش مُلبّدة.

- زيادة التغذية أو سرعة القطع.



الشكل (2.2): أنواع الرايش [1]

5.2. سائل التبريد

إن عمليات القطع بمختلف أنواعها يصاحبها ارتفاع كبير في درجة الحرارة التي تتولد من مصدرين أساسيين هما:

1. الحرارة المتولدة من احتكاك الرايش بسطح الحد القاطع الأمامي والخلفي لأداة القطع.

2. الحرارة المتولدة من عملية القطع التي تحدث على سطح المشغولة.

وهذا الارتفاع في درجة الحرارة يتوزع على كل من أداة القطع والمشغولة والرايش الناتج من عملية القطع، ولهذا السبب يتم استخدام سائل التبريد من أجل تقليل الاحتكاك بين أداة القطع والمشغولة وبين أداة القطع والرايش، والذي بدوره يُقلل القدرة اللازمة للقطع، كذلك تعمل سائل التبريد على تصريف ونقل كمية كبيرة من الحرارة المتولدة في عملية القطع.

1.5.2. أنواع سائل التبريد [4]

تقسم سائل التبريد بحسب حالتها إلى نوعين أساسيين هما:

(a) الأنواع الغازية

هذا النوع قليل الاستخدام لأنه لا يحمل صفة التزييت وتوصيله الحراري ضئيل ومثال عليه الهواء، الأركون، وأكاسيد الكربون (CO_2 , CO).

(b) الأنواع السائلة

وهذا النوع يكون واسع الاستخدام في الصناعة بسبب خواص التزييت والتبريد التي يمتلكها وتقسم الأنواع السائلة إلى:

- الماء وهو مزيج من الماء الطبيعي وبعض الأملاح (أكسيد الصوديوم)، ويتميز برخصه وتوصيله الحراري الجيد ومن مساوئه أنه يُولد الصدأ على السطح المُشغل.

- الزيوت وتنقسم إلى:

(a) الزيوت الطبيعية يمتاز هذا النوع بلزوجته المنخفضة وخصائص ترطيب سريعة ولكنه يتغلغل

داخل المعدن بمعدل عالٍ وهذا يسبب تغيراً في خواص المعدن المُشغل، وتستخدم الزيوت الطبيعية

مع المعادن اللاحديدية.

(b) الزيوت الدهنية استخداماتها محدودة وقليلة بسبب كلفتها العالية وقابليتها على التّعفن السريع،

وتُستخدم في التطبيقات الثقيلة.

(c) الزيوت الطبيعية - الدهنية وهي مزيج من الزيوت الطبيعية والدهنية، ومن مميزاته أنه ذو كلفة

قليلة نسبياً بالمقارنة مع الزيت الدهني، ويعمل على تحسين الإنجاز السطحي للمعادن اللاحديدية

وكذلك للفولاذ ولا توجد أي تأثيرات على خواص المعدن المُشغل ويمتلك خواص تزييت عالية.

- الماء المستحلب وهو مزيج من الزيوت سواء كانت طبيعية أو دهنية مع الماء. يمتلك هذا النوع من

سوائل التبريد خصائص تبريد عالية وهو شائع الاستعمال في معظم عمليات القطع بسبب كلفته

المنخفضة.

6.2. تعريف عملية الخراطة

الخراطة هي عملية قطع المعدن والتي تُستخدم لتوليد سطوح أسطوانية بوساطة آلة تُسمى المخرطة (Lathe)،


وعادةً تكون المشغولة هي التي تدور على عمود الدوران وأداة القطع تُغذى داخلها إما محورياً أو قطرياً أو كلا

الطريقتين بشكل متزامن لإعطاء السطح المطلوب [4]. إن اتجاه حركة التغذية المحوري هو السائد في عملية

الخراطة بالنسبة لعمود دوران الآلة، أما التغذية القطرية فهي السائدة في عملية التسوية (Facing)، أما السطوح

المخروطية والكنثرورية فإنها تحتاج إلى كلا النوعين من التغذية في الوقت نفسه، وغالباً يُشار إليها بمصطلح

(Profiling) كما هو موضح بالشكل (3.2).




الشكل (3.2): عمليات الخراطة [1]

1.6.2. العمليات التي يمكن إنجازها على المخرطة:

إضافة إلى الخراطة والتسوية فإن هنالك عمليات تشغيل متنوعة أخرى يمكن إنجازها على المخرطة وهي موضحة في الشكل (4.2) وهي:

- الشطب (Chamfering) وهو ما يعرف أيضاً بالشمفرة، إذ تُستخدم الأداة لقطع زاوية على زاوية السطح الخارجي الأسطواني للمشغولة كما هو موضح بالشكل (a.4.2).
- الفصل (Parting) يتم تغذية الأداة قطرياً داخل المشغولة التي تدور عند موضع معين على طول المشغولة لقطع نهاية الجزء كما هو موضح بالشكل (b.4.2).
- التسنين (Threading) وتستخدم لإنتاج الأسنان الداخلية والخارجية كما هو موضح بالشكل (c.4.2).

- توسيع الثقب (Boring) وتستخدم لتوسيع الثقوب إذ تُثبت أداة توسيع الثقب على الغراب المتحرك كما هو موضح بالشكل (d.4.2).
- الثقب (Drilling) يتم تثبيت أداة الثقب على الغراب المتحرك وتستخدم لإنتاج الثقوب بواسطة تغذية أداة الثقب داخل المشغولة الدوارة على طول محورها كما هو موضح بالشكل (e.4.2).
- التخريش (Knurling) وتستخدم لإنتاج سطح خشن مُهَشَّر بشكل عرضي على سطح المشغولة كما هو موضح بالشكل (f.4.2).



الشكل (4.2): العمليات التي يمكن إنجازها على المخرطة [1]

7.2. هندسة أداة القطع

تُعدّ أداة القطع المستخدمة في عمليات الخراطة أداة قطع مفردة الاتصال، وهذا يعني أن حافة قطع واحدة فقط هي التي تقوم بعملية التشغيل. تعتمد هندسة أداة القطع بشكل رئيسي على خواص مادة الأداة والمشغولة، والشكل (5.2) يوضح مصطلحات أداة القطع المستخدمة في الخراطة وفيما يأتي وصف لهذه المصطلحات:

1. وجه الأداة (Face): هو السطح العلوي من مقدمة طرف الأداة الأمامي والذي ينساب عليه الرايش.
2. نصف قطر المقدمة (Nose Radius-r): وينشأ من تقاطع حافة القطع الرئيسية مع حافة القطع المساعدة، ويمكن أن تكون المقدمة حادة الزاوية أو مستديرة.
3. زاوية الجرف (γ Rake Angle): تؤدي هذه الزاوية دوراً مهماً في عملية تشكيل الرايش إذ بزيادتها يسهل دخول الأداة في المعدن ويقل تشوه الجزء المنزوع ويتحسن انسياب الرايش وتقل قوة القطع وتزداد جودة السطح المشغل. تُقسم زاوية الجرف إلى زاوية الجرف الخلفية (γ_y Back Rake Angle) وزاوية الجرف الجانبية (γ_x Side Rake Angle).
4. زاوية الخلوص (α Clearance Angle) وتُسمى أيضاً (α Relief Angle): وهي مهمة لتقليل الاحتكاك بين حافة القطع وسطح المشغولة، ومن ثم زيادة عمر الأداة وزيادة قدرة الآلة في أثناء التشغيل. إن زيادة زاوية الخلوص عن الحد المقرر يؤدي إلى إضعاف مقطع الأداة ويجعله معرضاً للكسر، هنالك نوعان من زاوية الخلوص هما زاوية الخلوص النهائية (α_y End Relief Angle) وزاوية الخلوص الجانبية (α_x Side Relief Angle) [3].

5. زاوية الموشور (β Wedge Angle): وهي الزاوية المحصورة بين السطح الأمامي ووجه الأداة، وكلما كبر مقطع الأداة زادت قيمة زاوية الموشور، ويجب أن تكون هذه الزاوية كبيرة من أجل تحمّل الصدمات والقوى المؤثرة في الأداة في أثناء التشغيل، وكلما صغر هذا المقطع أصبح سهل الكسر، كما أنها تزداد

كلما كان المعدن المقطوع يمتلك قساوة عالية. ويُلاحظ أن مجموع هذه الزوايا الثلاث يساوي $(\beta + \gamma + \alpha = 90)$.


6. زاوية حافة القطع (Cutting Edge Angle - ϕ): وهي الزاوية المسؤولة عن القطع وإزالة المادة من على سطح المشغولة وهي على نوعين هما :

(a) زاوية حافة القطع الجانبية (Side Cutting Edge Angle - ϕ_s): وهي التي تُحدد

ثخانة الجزء المُزال وعرضه إذ تنقص الثخانة عند نقصان هذه الزاوية يرافقه زيادة في عرض الجزء المُزال، وتتوزع بفضل هذا الحرارة الناتجة في عملية القطع على مسافة أكبر من حافة القطع والذي يُحسّن عملية تصريف الحرارة من حافة القطع وزيادة ثبات الأداة وهذا يسمح بزيادة القطع وتشغيل عدد أكبر من المشغولات في الوحدة الزمنية. إلا إن تقليل هذه الزاوية يؤدي إلى زيادة قوى القطع وتزداد بشكل خاص القوة المحورية الدافعة، وهذا ما يؤدي إلى انحناء القطع غير الجائئة عند تشغيلها وإلى انعدام الدقة وكذلك إلى ظهور الاهتزازات في المشغولة والأداة وهذا يقلل من جودة السطح المُشغل [1].

(b) زاوية حافة القطع النهائية (End Cutting Edge Angle - ϕ_e): وتعمل على تقليل

الاحتكاك بين السطح الخلفي المساعد للأداة وسطح المشغولة المعرض للتشغيل.



الشكل (5.2): مصطلحات أداة القطع المستخدمة في الخراطة [4]

8.2. ظروف القطع

بعد أن يتم اختيار الآلة وأداة القطع لإجراء عملية تشغيل معينة، يجب أن تؤخذ ظروف القطع الرئيسية بالحسبان، واختيار ظروف القطع سوف يؤثر في إنتاجية عملية التشغيل عموماً، وعلى عمر أداة القطع، والحرارة المتولدة واستهلاك الطاقة والإنهاء السطحي خصوصاً وهي:

1- سرعة القطع (Cutting Speed)

تُشير سرعة القطع إلى سرعة السطح النسبية بين الأداة والمشغولة مُعبّرًا عنها بوحدة (m/min)، ويمكن أن تتحرك المشغولة أو الأداة أو كلاهما في أثناء القطع. هنالك عوامل عديدة تعتمد عليها سرعة القطع ويمكن إجمالها بالآتي :

1. نوع المعدن المراد قطعه.
2. معدن الأداة.
3. قابلية الأداة والمشغولة للتوصيل الحراري.
4. نوعية سطح المشغولة المنتجة.
5. هندسة أداة القطع.
6. عمق القطع ومعدل التغذية.
7. نوع عملية القطع (تخشين أو تنعيم).

ويمكن أن تُحسب سرعة القطع من القانون الآتي:

$$v_c = \frac{\pi DN}{1000} \dots (1.2)$$

إذ:

v_c : سرعة القطع (m/min)

D : قطر المشغولة (mm)

N : دورة بالدقيقة (r.p.m)

2- عُق القطع (Depth Of Cut)

عمق القطع متعلق بعمق حافة أداة القطع الذي تصل إليه في أثناء تعشُّقها بالمشغولة. ويُحسب عمق القطع ببعد خطي واحد لمساحة القطع، ويمكن حساب عمق القطع من القانون الآتي:

$$d_p = \frac{D_1 - D_2}{2} \dots (2.2)$$

إذ:

d_p : عُق القطع (mm)

D_1 : قطر المشغولة الابتدائي (mm)

D_2 : قطر المشغولة النهائي (mm)

3- مُعَدَّل التغذية (Feed Rate):

إن مُعَدَّل التغذية للخراطة التي تتم على آلة المخرطة هو التقدم المحوري للأداة على طول المشغولة لكل دورة للمشغولة.

تمتلك سرعة القطع، معدل التغذية وعمق القطع تأثيراً مباشراً على الإنتاجية، وعمر الأداة وأكبر تأثير هو على خشونة السطح لذلك يجب اختيار هذه العناصر بكل عناية.

9.2. الخلاصة

في هذا الفصل كان من الضروري التعرف إلى نظرية القطع عموماً، وعملية الخراطة خصوصاً، ومواد أدوات القطع التي يتم تصنيعها منها، وأيضاً على سوائل التبريد المستخدمة في أثناء عمليات التشغيل، وأنواع عمليات التشغيل التي يمكن تنفيذها على المخرطة، وظروف القطع الواجب تحديدها في أثناء تشغيل المشغولات وغيرها من الأمور الواجب معرفتها لتنفيذ الجزء العملي من هذا البحث.

الفصل الثالث: خشونة السطح

1.3. مقدمة

تؤدي جودة السطح من حيث النعومة دوراً مهماً في التطبيقات التي تتضمن الاحتكاك، إذ يجب أن تكون خشونة السطح في أدنى قيمة لها لضمان دقة أبعاد الجزء، وكذلك الدقة في تداخله مع الجزء الآخر [1]. إن خشونة السطح تنتج بشكل أساسي من عمليات التشغيل التي تترك أنماط متنوعة وواسعة على السطح المُشغل.

2.3. المصطلحات التي تُستخدم لوصف السطح وتحديد جودته هي [5]:

1. الرصف (Lay)

ويستخدم هذا المصطلح لوصف اتجاه نمط السطح المتكرر بواسطة عملية التشغيل.

2. الخشونة (Roughness)

وهي تعبر عن مقدار الفراغات الدقيقة الناتجة من عدم انتظام السطح وتنتج الخشونة من عمليات التشغيل.

3. ارتفاع الخشونة (Roughness Height)

وهو ارتفاع عدم انتظام السطح مستند إلى خط مرجعي، ويطلق عليه أيضاً ارتفاع التفاوتات.

4. عرض الخشونة (Roughness Width)

هو المسافة الموازية للسطح الاسمي بين القمم أو النتوءات المتتالية والتي تُحدد النموذج السائد للخشونة.

5. التموج (Waviness)


ويشير إلى عدم الانتظام في السطح ذي الفراغات الأوسع من الخشونة وهو ناتج من الالتواء والاهتزاز.

6. ارتفاع التموج (Waviness Height)

ويمثل المسافة بين القمة إلى الانخفاض للمقطع الجانبي للسطح.

7. الخدوش (Flaws)

وهي شقوق تنتج على السطح المشغل نتيجة لرداءة حافة أداة القطع، والشكل (1.3) يبين هذه المصطلحات.



الشكل (1.3): مصطلحات خشونة السطح [6]

3.3. تأثير زيادة خشونة السطح في الأجزاء

تؤثر خشونة السطح بشكل كبير في أداء عمل الأجزاء واستمراريتها في العديد من التطبيقات الهندسية لأن السطح الخشن يتآكل بشكل أسرع وله معامل احتكاك أكبر من السطح الناعم. أيضاً السطح الخشن هو مؤشر جيد لأداء الأجزاء لأن هذه النتوءات توفر مواقع سهلة الكسر وأكثر قابلية لتشكّل الصدأ وهو أمر يسهم بشكل كبير في تحديد مدى قدرة هذه الأجزاء على تحمل الضغوط على المدى الطويل. على الجانب الآخر، يمكن أن تسهم خشونة السطح في تعزيز التصاق المواد في بعض الحالات المرغوب فيها. تساعد الخشونة السطحية في تحسين جودة المنتجات كما تساعد على تقليل تكاليف الصيانة والإصلاح، لذلك يُعدّ الحفاظ على خشونة السطح مهماً جداً لضمان جودة المنتجات وللحفاظ على سمعة المصنع أو المؤسسة.

4.3. طرائق تقييم درجة نعومة السطح [5]

هناك طرائق حسابية عدة تستخدم لتقدير خشونة السطح الناتجة من عمليات التشغيل المختلفة، وهذه الطرائق هي:


1.4.3. طريقة المتوسط الحسابي للانحرافات R_a

تعتمد هذه الطريقة على الارتفاع المتوسط R_a لتقييم درجة نعومة السطح . حيث يؤخذ الخط المتوسط بحيث يكون مجموع مساحات النتوءات فوقه مساوية لمجموع مساحات الانخفاضات تحته أو بتعبير آخر بحيث يصل مجموع مربعات الإحداثيات الشاقولية المأخوذة عبر مسافات أفقية إلى الحد الأدنى، أما الارتفاع المتوسط R_a فهو يعبر عن قيمة الخشونة المتوسطة بدءاً من الخط المتوسط وهو عبارة عن الارتفاع الوسطي لمجموع مساحات النتوءات الواقعة فوق الخط المتوسط والانخفاضات الواقعة تحته من دون الالتفات إلى إشارة المساحة. وتعرف قيمة الخشونة المتوسطة R_a : بأنها المتوسط الحسابي لمدى ابتعاد الانحرافات عن البعد الفعلي المتوسط.

$$R_a = \frac{a_1 + a_2 + \dots + a_n}{L} \dots (1.3)$$

$$R_a = \frac{1}{L} (y_1 + y_2 + \dots + y_n) \dots (2.3)$$

$$R_a = \frac{1}{L} \int_0^L y(x) dx \dots (3.3)$$



إذ إن:

R_a : خشونة السطح


L : الطول التقديري

y : الارتفاع والانخفاض

x : المسافة على طول القياس

2.4.3. طريقة الارتفاع الأعظمي للتعرجات R_{max}

يعبر عن خشونة السطح بهذه الطريقة من خلال المسافة الفاصلة بين أعلى قمة وأخفض أخدود للنتوءات الميكروية السطحية حيث يتم أخذ عينة من السطح بطول كاف مقداره L يحوي عدداً متوسطاً من التعرجات ثم يرسم خط يمس أعلى قمة لهذه التعرجات وخط آخر يمس أخفض أخدود والمسافة بينهما R_{max} تتخذ أساساً لتقييم الخشونة (درجة تنعيم السطح).



الشكل (2.3): تأثير بنية السطوح في مساحة التلامس [5]

3.4.3. طريقة النقاط العشر للتعرجات:


يعبر الارتفاع R_z عن الارتفاع الوسطي للنتوءات الميكروية وتستخدم عشر نقاط لحساب R_z وبالتالي يكون

الارتفاع الوسطي مساوياً لمجموع أعلى خمس قمم مع أخفض خمسة أخاديد وتقسيم المجموع على عشرة.

وهذه الطريقة متبعة من قبل عدد كبير من الدول الصناعية ولذلك عند تصميم الرسوم الهندسية توضع قيم

الارتفاع المتوسط R_z على السطوح بحيث يتم تثبيت قيمتين لـ R_z القيمة الأولى تمثل الحد الأدنى والقيمة

الثانية تمثل الحد الأعلى كما هو مبين في الشكل (3.3)



الشكل (3.3): طريقة النقاط العشرة للتعرجات [5]


$$R_z = \frac{(R_1 + R_3 + R_5 + R_7 + R_9) + (R_2 + R_4 + R_6 + R_8 + R_{10})}{10} \dots (4.3)$$

5.3. مقاييس الخشونة [5]

لكي يتم وصف خشونة السطوح بطريقة محددة كان لابد من الاتفاق على مقاييس عددية تعبر عن درجة خشونة السطح وقد اتفق المختصون في هذا المجال على عدد من المقاييس العددية لتكون مقاييس موحدة تستخدم للتمييز بين السطوح ذات درجات الخشونة المختلفة وهذه المقاييس هي:

1.5.3. عمق الخشونة R_t


هو البعد بين الحد الأقصى والحد الأدنى للانحرافات أو هو أقصى ارتفاع بين أعلى قمة وأدنى قاع على الطول المختبر كما هو مبين في الشكل (4.3) ويعد عمق الخشونة من أكثر المقاييس المستخدمة لتقييم بنية السطوح ولكنه لايعطي فكرة واضحة عن الخواص الانزلاقية للسطوح ومقاومتها، لذلك يتم الاستعانة بمقاييس أخرى لخشونة السطح للوصول لأعلى دقة في تقييم السطوح.



الشكل (4.3): مقياس عمق الخشونة [5]

2.5.3. عمق الاستواء (التسطيح) R_p

هو البعد بين الحد الأقصى والخط المرجعي المتوسط للانحرافات (البعد بين البنية المتوسطة والبنية الإسنادية) الشكل (5.3). ويدل هذا المقياس على المقدار اللازم لضغط قمم التموج الفعلية حتى تصبح مستوية، ويمتاز هذا المقياس عن المقاييس الأخرى للخشونة بأنه يعطي أفضل بيان عن الأداء الوظيفي للسطح مثل السطوح الانزلاقية وسطوح الإزواجيات التداخلية التي يتم تركيبها بالكبس.



الشكل (5.3): عمق الخشونة R_t ، عمق التسطيح R_p [5]

3.5.3. العمق الأدنى للخشونة R_v


هو البعد بين الحد الأدنى والخط المرجعي المتوسط للانحرافات. الشكل (5.3) يبين كلاً من مقاييس الخشونة R_v, R_p, R_T التي ترتبط ببعضها البعض بالعلاقة الآتية:

$$R_T = R_p + R_v$$

4.5.3. متوسط أقصى انحرافات للسطح R_z

هو متوسط الفرق بين أعلى خمسة انحرافات P_1, P_2, P_3, P_4, P_5 وأدنى خمسة انحرافات V_1, V_2, V_3, V_4, V_5 في العينة المقاسة وطبقاً لمواصفات ISO وبالنظر إلى الشكل (6.3) نجد أن:

$$R_z = \frac{(p_1 + p_2 + p_3 + p_4 + p_5) - (v_1 + v_2 + v_3 + v_4 + v_5)}{5} \dots (5.3)$$



الشكل (6.3): متوسط أقصى انحرافات السطح R_z [5]


5.5.3. طريقة متوسط الجذر التربيعي (Root Mean Square Average)

هو الجذر التربيعي لمتوسط مجموع مربعات الانحرافات. وتظهر أهمية هذه المقياس عند تقييم الخواص

الضوئية للسطوح، ويرمز لها اختصاراً (R_q) أو $(MRMS)$ ويمكن التعبير عنها بالمعادلة الآتية:

$$R_q = \sqrt{\frac{z_1^2 + z_2^2 + z_3^2 + \dots + z_n^2}{n}} \dots (6.3)$$

$$R_q = \sqrt{\frac{1}{L} \int_0^L y^2(x) dx} \dots (7.3)$$



إذ إن:

n : عدد الارتفاعات

Z : الارتفاع.

6.3. أجهزة قياس الخشونة [7]

هناك العديد من الأجهزة المستخدمة اليوم في قياس خشونة السطح، وتتميز هذه الأجهزة عن بعضها بعضاً بمدى دقتها ومبدأ عملها، ويمكن أن تقسم أجهزة قياس الخشونة إلى ثلاثة أقسام رئيسية:


1. أجهزة الاستشعار: وتعتمد على مبدأ تحريك إبرة على السطح المراد قياس خشونته.

2. الأجهزة البصرية: ويقوم مبدأ عملها على سقوط الضوء وانعكاسه من على السطوح المختبرة.

3. الأجهزة المجهرية: وتعتمد على استخدام المجهر لمعرفة تنوع السطح من حيث الخشونة.


1.6.3. أجهزة الاستشعار

تعتمد أجهزة الاستشعار والموضحة في الشكل (7.3) على مبدأ تحريك إبرة عبر السطح المراد فحصه لاستكشاف التنوع في الارتفاع كدالة للمسافة. إن أجهزة الاستشعار الأولى كانت تستخدم نظام العُتلات لتكبير الإزاحة العمودية للاستشعار لتسجيل المقطع الجانبي على صفيحة زجاجية (Smoked -Glass Plate) وهذا النوع من الأجهزة موضح في الشكل (8.3) والمسمى بمقياس خشونة توملينسون (Tomlinson Roughness Meter).



الشكل (7.3): جهاز الاستشعار لقياس الخشونة [7]

إن الخطوة التالية في تطور أجهزة الاستشعار كانت في دمج محوّل (Transducer) يُستخدم لتحويل الإزاحة العمودية إلى إشارة كهربائية، وهذه الإشارة يمكن معالجتها بعد ذلك بواسطة الجهاز إلكترونياً لحساب وسيط الخشونة المناسبة. إن نوع المحوّل المستخدم يؤثر بشكل كبير في عمل الجهاز وتستخدم غالباً بلورة كهروضغطية (Piezoelectric) كمحوّل في الأجهزة منخفضة الكلفة، وتتضمن آليات التحويل الأخرى محوّلات الملف المتحرك، والمحوّلات التفاضلية ذات المتغير الخطي (LVDT).




الشكل (8.3): مقياس خشونة توميلسون [7]

هنالك بعض الأخطاء التي يمكن أن تنتج في قياسات الخشونة عند استخدام أجهزة الاستشعار، وهذا يعود إلى الأسباب الآتية:

1. حجم إبرة الاستشعار (Stylus Size)

إن تأثير حجم إبرة الاستشعار موضَّح في الشكل (9.3) والذي يوضح مقارنة تخطيطية للمقطع الجانبي الحقيقي (Actual Profile) والمقطع الجانبي المقتفي (Traced Profile). إن التأثير لحجم الإبرة يصبح أكثر وضوحاً عندما يقل تقوُّس الارتفاعات والانخفاضات أو عندما يزداد الميل.



الشكل (9.3): تأثير حجم إبرة الاستشعار في دقة القياس [6]

2. حمل الاستشعار (Stylus Load)

لقد وُجدَ بأن التشوه اللدن يمكن أن يحدث على السطح إذا استُخدمت حمل أعلى من الموصى به بواسطة الأحمال

القياسية وهو موضح في الشكل (10.3).




الشكل (10.3): تأثير حمل الاستشعار [6]

3. سرعة إبرة الاستشعار (Stylus Speed)

إذا كانت سرعة إبرة الاستشعار عالية فيمكن أن تفقد الإبرة الاتصال مع السطح، ومع ذلك فقد وُجد أنه لمعظم السطوح تكون الأخطاء الناتجة من سرعة الإبرة غير مهمة أو ثانوية.


2.6.3. الأجهزة البصرية (Optical Instruments)

يعتمد مبدأ عمل هذه الأجهزة على تسليط حزمة من إشعاع كهرومغناطيسي وانعكاسه من على السطح الذي يتم اختباره، وهذا الانعكاس يتم بثلاث آليات هي: الانعكاس المرآوي (المنتظم) والانعكاس الانتشاري (Diffusely)، أو يتم بكلتا الآليتين معاً والشكل (11.3) يوضح الأشكال الثلاثة من الانعكاس.




الشكل (11.3): a- الانعكاس المرآوي b- الانعكاس الانتشاري c- الانعكاس المرآوي والانتشاري [6]

واعتماداً على خشونة السطح فإن الإشعاع المُسلط ذا الطول الموجي المحدد يمكن أن ينعكس مرآوياً، في حين الإشعاع لطول موجي آخر يمكن أن ينعكس انتشارياً، لذلك فإن مقدار الانعكاس المرآوي أو الانعكاس الانتشاري يمكن أن يستخدم لحساب خشونة السطح. أحد الأجهزة التي تستخدم الانعكاس المرآوي لوصف الخشونة هو مجهر المقطع الضوئي (Light – Section Microscope)، تقوم العدسة بالنقاط الصورة عند زاوية الانعكاس المرآوي فإذا كان السطح مصقولاً فسوف تكون الصورة الناتجة مستوية، أما إذا كان السطح خشناً فإنه سوف يتم ملاحظة نموذج متعرج في الصورة المنعكسة، وهذا الجهاز مناسب لقياس خشونة القمة إلى الانخفاض، والشكل (12.3) يبين مبدأ عمل هذا الجهاز.



الشكل (12.3): مبدأ عمل مجهر المقطع- الضوئي [6]

إن التأثير المتبادل للضوء المستقطب مع السطح يمكن أن يُستعمل لتقدير خشونة السطح، وهذا المبدأ جرى استخدامه في جهاز القطاع الجانبي البصري طويل المسار (Long-Path Length Optical Profile) الموضح في الشكل (13.3) والذي يُركّز حزمة ليزرية على السطح بواسطة مرآة متراصة قبل وصول الليزر للعينة المختبرة فإنه يذهب خلال موشور ولاستون (Wollaston Pris) الذي يقوم باستقطاب الحزمة إلى مركبتين متعامدتين. هذه الحزم تُركّز بعد ذلك بؤرياً على السطح إذ تنعكس راجعة للموشور. أخيراً يتم توجيه الحزم المنعكسة مباشرة إلى فالق الحزمة (Beam Splitter) الذي يُرسل كل حزمة إلى كاشف مختلف، إن الاختلاف الطوري للحزم المستقطبة والذي يتناسب مع الارتفاع عند السطح ينتج فرق جهد يمكن قياسه [6].



الشكل (13.3): جهاز القطاع الجانبي البصري طويل المسار [6]

تعتمد قدرة هذه الأجهزة على الارتباط العكسي بين شدة الانعكاس المرآوي ومتوسط الجذر التربيعي (RMS). إن أحد المزايا الرئيسية لهذه التقنية هي أنها تسمح بمعاينة سريعة للسطوح المتشابهة. إن درجة الوضوح العمودي هي

تقريباً (1nm). لقد وُجد بأن قياسات الخشونة التي تستخدم هذه التقنية لا ترتبط بشكل وثيق مع قياسات الاستشعار، ونتيجة لهذا فإن قراءات الجهاز يجب أن يتم معايرتها لكل نوع من المواد التي يتم اختبارها. التقنية الأخرى المستخدمة لوصف تضاريس السطح هي قياس الإهليلجية (Elipsometry)، إذ تعمل على قياس التغير في الاستقطاب بعد انعكاس شعاع ضوئي من السطح. إن هذه التقنية في القياس بقيت تحت البحث بسبب أنَّ مقدار دوران الشعاع يتأثر كذلك بعوامل السطح الأخرى مثل التركيب، درجة الحرارة، وحالة الانفعال وغيرها من العوامل.

3.6.3. الأجهزة المجهرية (Microscopic Instruments)

هنالك العديد من الأجهزة المستخدمة في هذا المجال ومن أهم هذه الأجهزة:

1.3.6.3. مجهر المسح النفقي (Scanning Tunneling Microscopy)

مجهر المسح النفقي (STM) يختلف عن بقية العمليات المجهرية الأخرى في كونه لا يستعمل عدسات، إضاءة خاصة أو مصدر إلكتروني. عوضاً عن ذلك مجهر المسح النفقي يستخدم الإلكترونات المقيدة الموجودة على العينة كمصدر للإشعاع، ويتم استخدام فولتية انحياز منخفضة (V_b)، تيار نفقي (I)، يمر خلال جُهد لسبر طرف المعدن.

إن المعادلة التي تصف التيار النفقي هي :

$$I \approx 18 \frac{V_b}{10^4 \times \Omega} \times \frac{k}{d} \times A_{eff} \times e^{-2dk} \dots (8.3)$$

إذ:


A_{eff} : المساحة المؤثرة لطرف الإبرة والتي تساعد في حساب درجة الوضوح الجانبية.

يمتلك مجهر المسح النفقي القدرة على العمل بأسلوبين هما:

1. أسلوب الارتفاع الثابت (Constant Height Mode)

2. أسلوب التيار الثابت (Constant Current Mode)

يسمح أسلوب الارتفاع الثابت بمسح سريع عبر السطح مع إبقاء فولتية الانحياز ثابتة. حلقة التغذية المرتدة (Feedback Loop) في النظام تُعَدّل باستمرار وتتابع التيار النفقي ويتم تسجيل أي تغيرات للتيار النفقي بشكل متزامن مع الموقع الممسوح والتي تستخدم لإنشاء الخريطة النهائية للسطح. إن التصوير السريع للسطح المستوية ذرياً يتم عمله بسهولة خلال أسلوب الارتفاع الثابت نتيجة لحقيقة كون حلقة التغذية المرتدة والمضخم الكهروضغطي لا يُصحح باستمرار لأي تغيرات سطحية، كما هو مبين في الشكل (a.14.3).




الشكل (14.3): a- أسلوب الارتفاع الثابت b- أسلوب التيار الثابت [6]

أما في أسلوب التيار الثابت فإن طرف الإبرة يمسح عبر السطح والتيار النفقي يبقى ثابتاً. بعدها يُعَدّل ارتفاع طرف الإبرة باستمرار بواسطة مراقبة فولتية التغذية الخلفية (V_f). حالما يبدأ طرف الإبرة بالمسح للسطح

المستوي الكلي باتجاه (x-y) سوف يتولد سطح (3D) مستخدماً فولتية التغذية الخلفية. في حالة أسلوب التيار الثابت تستخدم حلقة التغذية الخلفية معالجة أكبر مما هو عليه في أسلوب الارتفاع الثابت مسببة إعاقة أكثر للسرعة بوساطة حلقة التغذية الخلفية. الشكل رقم (b.14.3) يوضح أسلوب التيار الثابت إذ يحافظ طرف الإبرة على مسافة ثابتة فوق سطح المادة. إن تركيب طرف الإبرة مهم جداً لعملية المسح النفقي وطرف الإبرة عموماً من التنغستين، أو الذهب. إضافة إلى ذلك يجب أن يتم شذ الطرف حتى يشبه كثيراً القلم، واعتماداً على نوع الفولتية المطبقة للنظام (AC/DC) فإن الطرف يمكن أن يمتلك أشكالاً مختلفة. إذا كانت الفولتية المطبقة (AC) عندها يكون الطرف بشكل مخروطي وهو مفضل جداً للتصوير عالي الوضوح. أما إذا كانت الفولتية المطبقة (DC) عندها يكون الطرف بشكل قطع زائد، وتعتمد درجة وضوح المادة بشكل كبير على شكل طرف الإبرة، إذ كلما قلت زاوية الطرف زادت الدقة [7].

2.3.6.3. مجهر القوة الذرية (Atomic Force Microscopy)

تُستخدم هذه الطريقة التي يرمز لها اختصاراً (AFM) طرف إبرة (Probe Tip Cantilever) لاستكشاف القوى الضعيفة على سطح المشغولة، في حين يتحرك النموذج في اتجاه (x-y) فإن النهاية المتمركزة للإبرة يمكن أن تصنع الاتصال مع سطح المشغولة أو تعمل بإسلوب لا اتصال. يتحرك المسح على طول اتجاه (x-y)، ويمكن أن تُجمع كل البيانات بوساطة استخدام الليزر، مجسات كهروضغطية، ومجسات كهروضوئية [7]. المجسات الكهروضغطية تُرسل فولتية للمحول، والمجس الكهروضوئي قادر على قياس الحركة مستنداً إلى التغيرات في زاوية السقوط. إن مبدأ عمل الليزر هو في أسلوب المجس الكهروضوئي نفسه، ومن ثم يمكن الحصول على أعلى درجة وضوح فقط في حالة أسلوب الاتصال أو في حالة قوى التناثر القوية، والشكل (15.3) يوضح جهاز (AFM).



الشكل (15.3): مبدأ عمل جهاز (AFM) [6]

6.3. الخلاصة

وفي ختام هذا الفصل تم التعرف إلى خشونة السطح وطرائق قياسها، والأجهزة المستخدمة في قياسها، ومدى أهميتها والتي من الضروري الإلمام بها كونها جزءاً أساسياً من هذا البحث.

الفصل الرابع: الذكاء الصُّنعي

1.4. مقدمة

يُعدّ العالم الأمريكي جون مكارثي John Mc Carthy هو الذي أوجد مصطلح الذكاء الصُّنعي في عام 1956م، وقد عرّفه بأنه علم وهندسة صناعة الآلات الذكية وهو فرع علم الحاسوب الذي يهدف إلى إنشاء الآلات الذكية.

ويمكن تعريف الذكاء الصُّنعي بأكثر من تعريف منها:

- الذكاء الصُّنعي هو محاولة لاكتشاف ووصف جوانب الذكاء البشري التي يمكن محاكاتها بوساطة الآلات (الكمبيوتر).
- أتمتة الأنشطة التي تربط الذكاء البشري بالفعل مثل: صناعة القرارات وحل المسائل والتعلّم....
- فن إنشاء آلات تتجز وظائف تتطلب ذكاء عندما يؤديها الإنسان.

2.4. علم الآلة Machine Learning

علم الآلة (Machine Learning) هو فرع من فروع الذكاء الصُّنعي كما هو مبين بالشكل (1.4) وهو عملية إدخال البيانات إلى الحاسوب بحيث يصبح قادراً على التعلّم من البيانات والخبرات السابقة، وتحسين أدائها تلقائياً دون الحاجة لتدخل بشري [15]. يجمع علم الآلة بين أفكار من علم الأعصاب والأحياء والإحصاء والرياضيات والفيزياء لجعل الحواسيب تتعلّم. يهدف علم الآلة إلى تطوير نماذج رياضية وأدوات حاسوبية تستخدم في حل مجموعة متنوعة من المشكلات مثل: التصنيف والتنبؤ والتحليل والتعرف إلى الأنماط وتحليل البيانات وغيرها من التطبيقات العملية، ولكن من سلبيات علم الآلة أنه لا يمكن زيادة الدقة بزيادة حجم البيانات كما هو مبين بالشكل (2.4).

1.2.4. أنواع علم الآلة

1. التعلّم الخاضع للإشراف (Supervised Learning): إذ يتم تقديم مجموعة من الأمثلة التدريبية

(المدخلات) مع الخرج الموافق لها (الأهداف)، واستناداً إلى مجموعة التدريب هذه يتم تعميم الخوارزمية

للاستجابة بشكل صحيح لجميع المدخلات الممكنة، ويسمى هذا أيضاً التعلّم من الأمثلة.

2. التعلّم غير الخاضع للإشراف (Unsupervised Learning): لا يتم توفير الخرج الصحيح في التعلّم

غير الخاضع للإشراف، ولكن بدلاً من ذلك تحاول الخوارزمية التعرف إلى النماذج والتشابهات بين

المدخلات وتجميعها معاً في فئات.

3. التعلّم المعزّز (Reinforcement Learning): وهو بين التعلّم الخاضع للإشراف والتعلّم غير

الخاضع للإشراف، إذ تُخبر الخوارزمية عندما تكون الإجابة خاطئة ولكن لا تُخبر كيفية تصحيحها، بل

يجب عليها استكشاف وتجربة احتمالات مختلفة حتى تتمكن من معرفة كيفية الحصول على الإجابة

الصحيحة. يتم استخدام التعلّم المعزّز في تطبيقات مثل: تدريب الروبوتات على القيام بمهام محددة،

تحسين أداء الألعاب وتطوير استراتيجيات التداول في الأسواق المالية.

4. التعلّم التطوري (Evolutionary Learning): يمكن النظر إلى التطوّر البيولوجي على أنه عملية تعلّم

بحيث تتكيف الكائنات الحية لتحسين معدلات بقائها على قيد الحياة وزيادة فرصة وجود ذرية في بيئتها.

3.4. التعلّم العميق Deep Learning

DL هو أحد فروع علم الآلة (ML) في الذكاء الصّنعى (AI) كما هو مبين بالشكل (1.4) إذ يتم إضفاء الذكاء


على الآلات أو الأنظمة من دون برمجة صريحة باستخدام خوارزميات مستوحاة من الوظائف الحيوية للدماغ

البشري.

تفوّق التعلّم العميق (DL) في المجالات الجديدة التي كان علم الآلة يفشل فيها، ومع مرور الوقت أدى البحث


والتجريب إلى فهم المجالات التي يمكن فيها الاستفادة من (DL) لجميع مهام (ML) وتوقع أداء أفضل بشرط

توفّر بيانات ضخمة كما هو مبين بالشكل (2.4) إذ تزداد دقة التعلّم العميق بزيادة حجم البيانات، ومن ثم أصبح (DL) مجالاً شائعاً لحل المشاكل التنبؤية بدلاً من التقيد بمجالات الرؤية الحاسوبية⁴ والكلام وما إلى ذلك.



الشكل (1.4): العلاقة بين الذكاء الصنعي وعِلْم الآلة والتعلّم العميق [15]

⁴ مجال في علوم الحاسوب والذكاء الصنعي يتعامل مع تطوير الأنظمة والتقنيات التي تمكّن الحواسيب من استيعاب الصور والفيديو بطريقة مشابهة للإدراك البصري للإنسان.




الشكل (2.4): زيادة دقة النموذج في التعلّم العميق بزيادة حجم البيانات [16]

4.4. الشبكات العصبونية Neural Networks

الشبكات العصبونية هي تنظيم هرمي من العصبونات (مشابهة للعصبونات في الدماغ) مع ارتباطات مع عصبونات أخرى. تُمرر هذه العصبونات رسالة أو إشارة إلى العصبونات الأخرى بناءً على المدخلات المستلمة وتُشكّل شبكة معقّدة تتعلم ببعض آليات التغذية الراجعة. الشكل رقم (3.4) يبين تمثيل بسيط للشبكة العصبونية التي تحتوي على: طبقة المدخلات (Input layer): التي تحتوي على بيانات الإدخال وتقوم بإعطاء المخرجات إلى الطبقة التي تليها والتي تُسمى الطبقة المخفية (Hidden layer) وهكذا حتى الوصول إلى طبقة الخرج (output layer) [16]. كل طبقة يمكن أن تحتوي على عصبون أو أكثر وكل واحدة منهم سوف تقوم بحساب وظيفة صغيرة تُدعى دالة التنعيل (activation function) والاتصال بين عصبونين في الطبقات المتتالية يتم بواسطة أوزان weights، والوزن يُحدّد تأثير المدخلات في الطبقة الحالية إلى العصبون في الطبقة اللاحقة وهكذا حتى


الوصول إلى طبقة الخرج. في الشبكة العصبونية تتم تهيئة الأوزان عشوائياً في أثناء عملية تدريب الشبكة، ولكن هذه الأوزان يتم تحديثها باستمرار حتى الوصول إلى التنبؤ بالشكل الصحيح. الشكل (4.4) يبين المدخلات $(..., x_1, x_2, x_3)$ مع الأوزان الموافقة لها $(..., w_1, w_2, w_3)$ ، وتتعلم الشبكة العصبونية من خلال إعطاء بيانات الإدخال والمخرجات للنموذج، وتقوم الشبكة باستخدام المدخلات وتحويلها إلى مخرجات عن طريق إيجاد علاقة بينهما، ولتحسين دقة التنبؤ تقوم بإعطاء قيمة راجعة للشبكة تُدعى Backpropagation أي تعديل الأوزان من أجل تحسين دقة التنبؤ، وبتكرار هذه العملية مرات عديدة وتعديل الأوزان تُصبح الشبكة قادرة على التنبؤ بالشكل الصحيح.



الشكل (3.4): الشبكة العصبونية [16]

1.4.4. Neuron العصبون

في الخلايا العصبية البيولوجية يتم إعطاء إشارة كهربائية كخرج عندما تتلقى مدخلات ذات تأثير أعلى. لتمثيل هذه الوظيفة في الخلايا العصبية الرياضية نحتاج إلى أن يكون لدينا دالة تعمل على ضرب كل المدخلات مع الأوزان المقابلة لها ثم تقوم بجمعها ويشار إليها باسم $f(z)$ كما هو مبين بالشكل (4.4) وتستجيب بقيمة مناسبة تستند إلى المدخلات [17]. عند استلام إشارة واردة بتأثير أعلى يجب أن يكون الخرج (الناتج) أعلى والعكس صحيح (أي أعلى تأثير ثم تنشيط، وإلا إلغاء التنشيط). الوظيفة التي تعمل على البيانات المحسوبة للإشارة الواردة تسمى وظيفة التنشيط (التفعيل).



الشكل (4.4): المدخلات مع الأوزان الموافقة لها [16]

2.4.4.2.4.4 Activation Functions [16]

هي الدالة التي تأخذ المدخلات المجمعة كما هو مبين في الشكل (4.4) وتطبق دالة عليها ثم تُعطي قيمة الخرج، وتُحدّد دالة التفعيل حالة العصبون عن طريق حساب دالة التفعيل على المدخلات المجمعة.


هنالك العديد من أنواع التفعيل التي يمكن استخدامها كما هو مبين في الشكل (7.4) ومن أهمها:

• Sigmoid Activation Function

يمكن تمثيله بالعلاقة $\frac{1}{(1+e^{-z})}$ التي تعطي قيمة للخرج إما 0,1 ويقوم بتحسين عملية التعلم عندما يكون الخرج

لاخطياً، ويعتمد على مبدأ: عندما يكون التأثير كبيراً يكون الخرج مرتفعاً في حين عندما يكون التأثير قليلاً يكون

الخرج منخفضاً وهو موضح بالشكل (5.4).




الشكل (5.4): تابع sigmoid [16]

• Relu Activation Function








يستخدم دالة $f(z) = \max(0, z)$ وهذا يعني أنه إذا كان الناتج موجباً فإنه سيُخرج القيمة نفسها، وإلا سيُخرج

0. ومجال الدالة كما هو موضح بالشكل (6.4). تابع Relu هو تابع غير خطي ويعمل جيداً كتابع تفعيل

ولا يقوم فقط بتحسين الأداء بل يقوم بتقليل العمليات الحسابية في أثناء عمليات التدريب.



الشكل (6.4): تابع Relu [16]

Activation function	Equation	Example	1D Graph
Unit step (Heaviside)	$\phi(z) = \begin{cases} 0, & z < 0, \\ 0.5, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Sign (Signum)	$\phi(z) = \begin{cases} -1, & z < 0, \\ 0, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Linear	$\phi(z) = z$	Adaline, linear regression	
Piece-wise linear	$\phi(z) = \begin{cases} 1, & z \geq \frac{1}{2}, \\ z + \frac{1}{2}, & -\frac{1}{2} < z < \frac{1}{2}, \\ 0, & z \leq -\frac{1}{2}, \end{cases}$	Support vector machine	
Logistic (sigmoid)	$\phi(z) = \frac{1}{1 + e^{-z}}$	Logistic regression, Multi-layer NN	
Hyperbolic tangent	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	Multi-layer Neural Networks	
Rectifier, ReLU (Rectified Linear Unit)	$\phi(z) = \max(0, z)$	Multi-layer Neural Networks	
Rectifier, softplus	$\phi(z) = \ln(1 + e^z)$	Multi-layer Neural Networks	

Copyright © Sebastian Raschka 2016
(<http://sebastianraschka.com>)

الشكل (7.4): توابع التفعيل المستخدمة في الشبكات العصبونية [17]

3.4.4. توابع الخسارة The Loss Functions [18]

تابع الخسارة هو المقياس الذي يساعد الشبكة على فهم ما إذا كانت تتعلم في الاتجاه الصحيح وهو لبيان أن الشبكة تعمل على تحسين عملية التعلم في كل تكرار، أي تابع الخسارة يقوم بقياس الفرق بين القيم المتنبأ بها والقيم

الحقيقية. ومع زيادة التكرارات وتقليل قيمة الخسارة يتبين للشبكة أنها تتعلم في الاتجاه الصحيح، ومن أشهر توابع الخسارة المستخدمة في حالة كان الخرج مستمراً (أي رقماً مستمراً وليس حصراً 0,1):

• متوسط الخطأ التربيعي Mean Squared Error

أي يقوم بحساب متوسط الفرق التربيعي بين القيم الفعلية والقيم المتنبأ بها كما هو مبين في المعادلة:

$$\sum_{n=1}^k \frac{(Actual - predicted)^2}{k} \dots (1.4)$$

• متوسط الخطأ المطلق Mean Absolute Error

أي حساب متوسط الخطأ المطلق بين القيم الفعلية والقيم المتنبأ بها كما هو مبين في المعادلة:

$$\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \dots (2.4)$$

ويوجد أيضاً العديد من توابع الخسارة مثل: متوسط خطأ النسبة المطلق MAPE و متوسط الخطأ اللوغاريتمي المربع MSLE.

عندما يكون الخرج (0,1) ومثال على ذلك: عندما يكون الخرج الطالب سينجح أم لا أو الزبون سيشترى المنتج أم لا وغيرها من الأمثلة يمكن استخدام توابع الخسارة الآتية:

• Binary cross-entropy:

يُستخدم فقط عندما يكون الناتج متغيراً ثنائياً فقط أي مع نتيجتين محتملتين: (اجتياز/فشل) أو (نعم/لا)، ويمكن التعبير عنه بالمعادلة الآتية:

$$Loss = -[y * \log(p) + (1-y) * \log(1-p)] \dots (3.4)$$

• Categorical cross-entropy

يُستخدم عندما يكون الخرج غير ثنائي، أي الاحتمالات تكون أكثر من احتمالين مثال: الخرج يكون


(نعم/ لا/ ربما) أو (الصنف 1، الصنف 2، الصنف 3) ويعبر عنه بالمعادلة الآتية:

$$Loss = - \sum y_i \log_2 y_i \dots (4.4)$$

4.4.4. توابع التحسين Optimizers

أهم جزء في عملية تدريب الشبكة العصبونية هو تابع التحسين، وهو عملية إعطاء التغذية الراجعة Backpropagation للشبكة لتحسين الأداء. أول مسار للشبكة أنها تقوم باستخدام أوزان عشوائية لإعطاء الخرج، والشبكة في هذه الحالة تكون قادرة على التنبؤ، ولكن نسبة الخطأ تكون كبيرة ثم يأتي دور تابع الخسارة Loss function الذي يكون دوره مساعدة الشبكة في تقييم الأوزان هل هي جيدة أم لا للمدخلات، والمرحلة التالية تكون عملية تقليل الخسارة Loss function وهنا يأتي دور تابع التحسين Optimizer وهو خوارزمية رياضية يقوم باستخدام المشتقات، والمشتقات الجزئية وحساب التكامل إذ يقوم بتعديل الأوزان لتقليل الخسارة Loss function كما هو مبين بالشكل (8.4) إذ يتم ملاحظة كيفية تعديل الأوزان حتى الوصول إلى أقل خسارة Loss function. يُطلق على عملية حساب عينة تدريب واحدة من طبقة المدخلات إلى طبقة الخرج pass، وعادةً عملية التدريب تكون على شكل مجموعات batches (أي تقسيم المدخلات بشكل كامل إلى مجموعات تدعى batches)، ويتم هذا التقسيم بسبب قيود الذاكرة في النظام، وتقوم الشبكة بتحديث الأوزان بعد معالجة العينات كافة في المجموعة batch، وتُدعى عملية تمرير العينات كافة في المجموعة مع تعديل

أوزانها بالترار Iteration. ويُطلق مصطلح epoch على عملية معالجة العينات كافة الموجودة في المجموعات كاملةً مع تعديل أوزانها.



الشكل (8.4): كيفية تعديل الأوزان حتى الوصول إلى أقل خطأ [17]


ومن أشهر توابع التحسين المستخدمة في أثناء برمجة الشبكات العصبونية:

- الانحدار التدريجي (Stochastic Gradient Descent (SGD)

بعد مرور كل عينة يقوم بحساب الخسارة loss ثم تعديل الأوزان لتقليل هذه الخسارة قدر الإمكان، وهكذا يتم تعديل قيم الأوزان باستمرار، ومع ذلك تُعدّ عملية التحسين سريعة مقارنة بالعمليات الأخرى، ويتم تعديل الأوزان من خلال المعادلة الآتية:

$$\text{Weights} = \text{weights} - \text{learning rate} * \text{Loss} \quad \dots\dots(5.4)$$

Learning rate: معدّل التعلّم وهو أحد البارامترات التي تقوم بالتحكم بالأوزان للشبكة العصبونية أي يحدّد سرعة أو بطء الوصول إلى الأوزان المثلى، ويحدد مدى سرعة تحديث الشبكة العصبونية للمفاهيم التي تعلمتها. عندما يتم اختيار معدّل التعلّم منخفضاً تكون الشبكة ذات قيمة جيدة، ولكن تحتاج الشبكة إلى عدد كبير من epoch (أي تتطلب وقت أطول لعملية التدريب) بسبب التغيرات القليلة للأوزان في كل تحديث، في حين عندما يكون معدّل التعلّم مرتفعاً يكون تدريب الشبكة بشكل سريع، بسبب التحديثات السريعة للأوزان وتتطلب عدداً قليلاً من epoch ولكن الشبكة العصبونية الناتجة من معدّل التعلّم المرتفع تكون دون المستوى الأمثل، والشكل رقم (9.4) يبين الفرق بين معدّل التعلّم المنخفض والمرتفع [15].



الشكل (9.4): الفرق بين معدل التعلّم المنخفض والمرتفع [17]

• Adam

هو من أكثر خوارزميات التحسين شهرةً واستخداماً في التعلّم العميق. في معظم الحالات يمكن اختيار خوارزمية Adam بصورة عشوائية ونسيان خوارزميات التحسين الأخرى. تعمل هذه التقنية على حساب معدّل تعلّم متكيف لكل وزن أو بارامتر في الشبكة العصبونية بشكل ملائم. تعرّف التباين للانحدار للدالة الهدف وتستخدم تأثير مشترك لتحديث بارامترات الأوزان ويساعد التباين في تحسين العملية التعليمية بشكل فعال [17].

يمكن التعبير عن هذه الخوارزمية بالمعادلة الآتية:

$$(6.4) \dots \text{التباين} - \text{الأوزان} = \text{الأوزان}$$

وهناك العديد من خوارزميات التحسين الشائعة الأخرى التي يمكن استخدامها أيضاً في نماذج DL المختلفة

ومنها: Nadam, Adamax, RMSProp, Adadelta, Adagrad

5.4.4. تطبيقات الشبكات العصبونية [18]

تعدّ الشبكات العصبونية (ANN) واحدة من أقوى التقنيات وأكثرها تنوعاً وفاعلية في القرن الحادي والعشرين. في السنوات الأخيرة وجدت الشبكات العصبونية طريقها إلى العديد من الصناعات والتطبيقات بدءاً من التعرف إلى الكلام ومعالجة الصور إلى التنبؤ المالي وتشخيص الأمراض الطبية ومن أفضل تطبيقات الشبكات العصبونية:

- (1) التعرف إلى الصور والرؤية الحاسوبية: التعرف إلى الصور هو واحد من أشهر التطبيقات للشبكات العصبونية. في الرؤية الحاسوبية تُستخدم الشبكات العصبونية للتعرف إلى الأشياء والأشخاص والمشاهد في الصور ومقاطع الفيديو، ويمكن للشبكات العصبونية أن تتعلّم وتصدر توقعات حول محتوى الصورة. هذه التكنولوجيا تُستخدم في العديد من المجالات بما في ذلك المراقبة، المركبات الذكية والتصوير الطبي.
- (2) التعرف إلى الكلام ومعالجة اللغة الطبيعية: التعرف إلى الكلام ومعالجة اللغة الطبيعية هما تطبيقان آخزان شهيران للشبكات العصبونية. في التعرف إلى الكلام تُستخدم الشبكات العصبونية لتحويل الكلمات المنطوقة إلى نص مكتوب، في حين تُستخدم في معالجة اللغة الطبيعية لتحليل النصوص وفهم معناها. تُستخدم هذه التقنيات في مساعدي الصوت الافتراضي، روبوتات الدردشة لخدمة العملاء وتطبيقات أخرى تتطلب القدرة على الفهم والاستجابة للكلام البشري.
- (3) التنبؤ المالي والتداول: التنبؤ المالي والتداول هما مجالان تُستخدم فيهما الشبكات العصبونية للتنبؤ باتجاهات السوق وأسعار الأسهم. يمكن للشبكات العصبونية تحليل كميات كبيرة من البيانات المالية واكتشاف الأنماط والعلاقات التي يمكن استخدامها لاتخاذ القرارات. تُستخدم هذه التكنولوجيا من قبل صناديق الاستثمار والبنوك والمؤسسات المالية الأخرى لتحسين استراتيجيات الاستثمار وتقليل المخاطر.
- (4) تشخيص الأمراض وتخطيط العلاج: هما تطبيقان حيويان للشبكات العصبونية. في التشخيص الطبي تُستخدم الشبكات العصبونية لتحليل الصور الطبية وبيانات المرضى لتحديد الأمراض والاضطرابات. في تخطيط العلاج تُستخدم الشبكات العصبونية لوضع خطط علاج شخصية استناداً إلى خصائص المريض الفردية. تساعد هذه التقنيات في تحسين دقة التشخيص والعلاج وفعالتهما للرعاية الصحية.

(5) المركبات ذاتية القيادة: المركبات ذاتية القيادة هي واحدة من أكثر التطبيقات إثارة للاهتمام للشبكات العصبونية. في المركبات ذاتية القيادة تُستخدم الشبكات العصبونية لتحليل البيانات واتخاذ القرارات حول كيفية استجابة المركبة لبيئتها. تُستخدم هذه التكنولوجيا لتطوير السيارات ذاتية القيادة والطائرات من دون طيار وغيرها من المركبات التي يمكنها العمل دون تدخل بشري.

(6) توليد اللغة الطبيعية: توليد اللغة الطبيعية هو تطبيق حديث نسبياً للشبكات العصبونية والذي يكتسب شهرة بسرعة. في توليد اللغة الطبيعية تُستخدم الشبكات العصبونية لإنشاء نصوص تشبه الكتابة البشرية. تُستخدم هذا التكنولوجيا في كتابة مقالات الأخبار، التقارير، وأشكال أخرى من المحتوى التي تتطلب القدرة على الكتابة بأسلوب طبيعي وجذاب.

(7) اكتشاف الاحتيال: اكتشاف الاحتيال هو تطبيق مهم للشبكات العصبونية يُستخدم لمنع الخسائر المالية وحماية الأعمال والمستهلكين. في اكتشاف الاحتيال تُستخدم الشبكات العصبونية لتحليل المعاملات المالية والكشف عن نشاط احتيالي. تُستخدم هذه التكنولوجيا من قبل البنوك وشركات بطاقات الائتمان والمؤسسات المالية الأخرى لتحسين إجراءات الأمان وتقليل مخاطر الاحتيال.

(8) تحسين سلاسل التوريد: إن تحسين سلاسل التوريد واحدة من المجالات التي تُستخدم فيها الشبكات العصبونية لتحسين الكفاءة وتقليل التكاليف. في تحسين سلاسل التوريد تُستخدم الشبكات العصبونية لتحليل البيانات من مراحل مختلفة في سلسلة التوريد بدءاً من المواد الخام حتى المنتجات النهائية لتحديد العقبات والفاقد. تساعد هذه التكنولوجيا الشركات في تبسيط سلاسل توريدها، تقليل الهدر وتحسين الأداء العام.

(9) الصيانة التنبؤية: تُستخدم في تحسين قابلية التشغيل وتقليل التوقف. في الصيانة التنبؤية يتم استخدام الشبكات العصبونية لتحليل البيانات من حساسات المعدات التي تشير إلى احتمالية فشل المعدات. تساعد هذه التكنولوجيا الشركات في تقليل تكاليف الصيانة، وتحسين قابلية التشغيل للمعدات وتقليل التوقفات غير المخطط لها.

5.4. الخوارزميات الجينية Genetic algorithms

1.5.4. مقدمة

تقترح نظرية الانتقاء الطبيعي أن النباتات والحيوانات الموجودة اليوم هي نتيجة ملايين السنين من التكيف مع البيئة. في خوارزميات البحث يتوفر عدد من الحلول الممكنة لمشكلة ما والمهمة هي إيجاد أفضل حل ممكن في فترة زمنية محددة، ومع ذلك سرعان ما يصبح هذا البحث الشامل غير عملي مع نمو مساحة البحث في الحجم. يُحدّد البحث التقليدي خلال البحث حلاً واحداً في كل مرة على أمل إيجاد الحل الأمثل في حين الجانب الرئيسي الذي يُميّز خوارزمية البحث التطوري عن مثل هذه الخوارزميات التقليدية هو أنها قائمة على السكان من خلال تكيف الأجيال المتعاقبة لعدد كبير من الأفراد إذ تقوم الخوارزمية التطورية بإجراء بحث موجّه فعّال.

2.5.4. تعريف الخوارزميات الجينية (GA)

قُدمت الحوسبة التطورية في الستينيات من قبل ريتشبرغ في كتاب "استراتيجيات التطور"، ثم طُوّرت هذه الفكرة من قبل عدة باحثين. اخترع جون هولاند الخوارزميات الجينية (GA) وطوّر هذه الفكرة في كتابه "التكيف في الأنظمة الطبيعية والاصطناعية" في عام 1975. اقترح هولاند GA كطريقة تجريبية تستند إلى "البقاء للأصلح" وقد تم اكتشاف GA كأداة مفيدة لمشاكل البحث والتحسين.

الخوارزميات التطورية هي محاولة تقليد بعض العمليات التي تحدث في التطور الطبيعي، ومن بين التقنيات التطورية تُعدّ الخوارزميات الجينية (GA) من الطرق الأكثر انتشاراً التي تُمثّل تطبيق الأدوات التطورية، وتعتمد بشكل أساسي على الاختيار، التزاوج، الطفرة ومن ثم عملية الاستبدال التي تحدث في الأجيال اللاحقة. تُعدّ الخوارزميات الجينية مثالاً على نقل التكنولوجيا الرياضية: من خلال محاكاة التطور يمكن حل مشاكل التحسين [19]. تستمر الخوارزميات الجينية بالحصول على أجيال أفضل من خلال تطبيق عمليات بسيطة للغاية، وتعدّ الخوارزميات الجينية حالياً من أبرز النماذج الحسابية المستخدمة على نطاق واسع للتطور في أنظمة

الحياة الاصطناعية. تُستخدم الخوارزميات الجينية اليوم في حل مشاكل التحسين المُعقَّدة: الجداول الزمنية،
جدولة متجر العمل، ممارسة الألعاب الإلكترونية.

تتميز الخوارزميات الجينية بميزتين [20]:

1. خوارزمية عشوائية: الاختيار العشوائي هو أساسي في الخوارزميات الجينية، إذ تجري عملية الاختيار والتكاثر عشوائياً.

2. تحتوي على مجموعة من الحلول: إذ تقوم بالحفظ في ذاكرتها أكثر من حل وهذا يُعطي العديد من الميزات، إذ تقوم بجمع حلول عدة مع بعضها بعضاً وهو أفضل من الحل الوحيد.

3.5.4. خطوات الخوارزميات الجينية [19]

(a) البدء Starting: توليد مجموعة من الحلول بشكل عشوائي (الحلول تُناسب المشكلة).

(b) اللياقة Fitness: تقييم كل حل من مجموعة الحلول من خلال دالة اللياقة $f(x)$.

(c) جيل جديد New generation: توليد جيل جديد من خلال تكرار الخطوات التالية حتى نحصل على الجيل الجديد:

1. الاختيار Selection: اختيار الحلول تبعاً للياقتهم (الحلول الأكثر لياقة هي التي تكون أكثر احتمالية ليتم اختيارها).


2. التزاوج Crossover: تُجرى عملية التزاوج لتشكيل جيل جديد، إذا لم يتم اختيار عملية التزاوج ومن ثم الجيل الجديد يكون نسخة طبق الأصل عن الجيل السابق.

3. الطفرة Mutation: يمكن أن تكون الطفرة في أي مكان في الحل.

4. القبول Acceptance: يتم قبول الحلول لإنشاء الجيل الجديد.

(d) الاختبار: إذا تم استيفاء الشرط الأخير، يتم إيقاف الخوارزمية وتُعيد أفضل حل من الجيل الحالي.

ويبين الشكل (10.4) هذه الخطوات:



الشكل (10.4): خطوات الخوارزمية الجينية [19]

4.5.4. أهم المصطلحات في الخوارزميات الجينية

1.4.5.4. الترميز

الترميز هو عملية تمثيل الجينات الفردية، ويمكن إجراء العملية باستخدام البتات أو المصفوفات أو الأرقام أو القوائم، ويعتمد الترميز بشكل أساسي على حل المشكلة، وأشهر أنواع الترميز:

- الترميز الثنائي

إن الطريقة الأكثر شيوعاً للترميز هي الترميز بشكل سلسلة ثنائية (بت) و هي موضحة بالشكل (11.4)، أي إن كل كروموسوم (حل) يُمثّل بشكل سلسلة ثنائية (بت)، ويمكن أن يُمثّل كل جزء في السلسلة بعض خصائص الحل. الترميز الثنائي يستخدم في الغالب مع الأعداد 1,0 وطول السلسلة من البتات يعتمد على الدقة.

Chromosome 1	1 1 0 1 0 0 0 1 1 0 1 0
Chromosome 2	0 1 1 1 1 1 1 1 1 1 0 0

الشكل (11.4): الترميز الثنائي [19]

- الترميز الثماني

هذا الترميز يستخدم سلسلة من الأعداد (0-7)، كما هو موضح بالشكل (12.4).

Chromosome 1	03467216
Chromosome 2	15723314

الشكل (12.4): الترميز الثماني [19]

- ترميز الرقم الحقيقي

في هذا الترميز كل كروموسوم (حل) هو عبارة عن سلسلة من الأرقام الحقيقية ولكن في بعض الأحيان يجب إجراء بعض التعديلات عند انتهاء عمل الخوارزمية الجينية، يبين الشكل (13.4) هذا الترميز.

Chromosome A	1 5 3 2 6 4 7 9 8
Chromosome B	8 5 6 7 2 3 1 4 9

الشكل (13.4): ترميز الرقم الحقيقي [19]

• ترميز القيمة

كل كروموسوم (حل) هو عبارة عن سلسلة من القيم وهذه القيم تكون متصلة بالمشكلة، ويُستخدم هذا الترميز في حالات خاصة. كل كروموسوم يمكن أن يكون أعداداً عشرية أو صحيحة أو أحرفاً أو يمكن أن تكون كلمات كما هو مبين بالشكل (14.4).

Chromosome A	1.2324 5.3243 0.4556 2.3293 2.4545
Chromosome B	ABDJEIFJDHDIERJFDLDFLFEGT
Chromosome C	(back), (back), (right), (forward), (left)


الشكل (14.4): ترميز القيمة [19]

2.4.5.4 الاختيار Selection

عملية الاختيار هي عملية انتقاء زوج من الحلول للتزاوج فيما بينهما من أجل إنشاء جيل جديد، والحل الذي يكون له أعلى دالة لياقة هو الحل الذي يكون له فرصة أعلى في الاختيار ومن أهمها:

- الاختيار عن طريق عجلة الروليت Roulette Wheel Selection:

اختيار عجلة الروليت هي واحدة من الطرائق التقليدية لخوارزميات الجينية وهي من أكثر الطرائق استخداماً. مبدأ عجلة الروليت يتم تقسيم هذه العجلة بحسب قيمة اللياقة لكل حل، ومن ثم الحل الذي تكون قيمة لياقته أعلى هو الحل الذي ستكون نسبة اختياره أعلى كما هو مبين بالشكل (15.4) [19].



الشكل (15.4): الاختيار عن طريق عجلة الروليت [20]

- الاختيار العشوائي Random Selection


تختار هذه التقنية عشوائياً أحد الحلول من الجيل للتزاوج، والاختيار العشوائي يُعدّ أكثر اضطراباً من اختيار عجلة الروليت.

3.4.5.4. التزاوج Crossover

بعد إجراء عملية الاختيار تتم عملية التزاوج عن طريق إجراء عملية التزاوج بين حلّين (آباء) من أجل إنتاج جيل جديد (أبناء)، والجيل الجديد يكون أفضل من الجيل السابق ومن أشهرها:

- التزاوج في نقطة واحدة Single Point Crossover


تستخدم الخوارزمية الجينية التقليدية التزاوج في نقطة واحدة، إذ يتم قطع الحلول في نقطة واحدة وتتم عملية التبادل بين الحلين بعد هذه النقطة وفي هذه الحالة يتم اختيار النقطة عشوائياً كما هو مبين بالشكل (16.4).



الشكل (16.4): التزاوج في نقطة واحدة [20]

- التزاوج في نقطتين Two Point Crossover

بالإضافة إلى التزاوج في نقطة واحدة، صُمم العديد من خوارزميات التزاوج المختلفة في كثير من الأحيان تشتمل على أكثر من نقطة تزاوج. يجب ملاحظة أن إضافة نقاط تزاوج إضافية يقلل من أداء الخوارزمية الجينية. في تقنية التزاوج في نقطتين يتم اختيار نقطتين للتزاوج وتتم عملية التبادل بين هاتين النقطتين بين الأبوين المتزاوجين. يُشار بالخطوط المنقطعة إلى نقاط التقاطع في تقنية التزاوج الجيني، إذ يتم تبادل المحتويات بين النقطتين من الأبوين المتزاوجين، والشكل رقم (17.4) يبين التزاوج في نقطتين.



الشكل (17.4): التزاوج في نقطتين [20]

5.5.4. اختلافات الخوارزميات الجينية عن خوارزميات الحل الأمثل التقليدية [21]

يوجد العديد من الاختلافات ما بين الخوارزميات الجينية وخوارزميات التحسين التقليدية ومن أهمها:

- تقوم الخوارزمية الجينية بترميز الحلول أي لا تتعامل مع الحل نفسه ولكن مع الترميز لهذا الحل.
- أغلب تقنيات البحث التقليدية تبحث من نقطة واحدة، ولكن الخوارزمية الجينية دائماً تبحث في مجموعة من الحلول، والذي بدوره يُعطي قوة للخوارزمية الجينية والذي يُحسِّن من الوصول إلى الحل الأمثل الشامل مع تجنب الوقوع في الحل عند نقطة معيَّنة.
- تستخدم الخوارزميات الجينية دالة اللياقة للتقييم عوضاً عن المشتقات، والذي بدوره يمكِّن الخوارزميات الجينية من حل أغلب المشكلات.

6.5.4. مزايا الخوارزميات الجينية وقيودها

تتجلى مزايا الخوارزميات الجينية في:

- التوازي
- القدرة على التعامل مع دالة اللياقة المعقّدة.
- القدرة على التعامل مع مشكلة متعددة الأهداف.
- تستخدم فقط دالة اللياقة من أجل التقييم.
- إمكانية التعديل بسهولة لتناسب مشاكل متعددة.
- إمكانية التعامل مع مساحات البحث الكبيرة، غير المفهومة بسهولة.
- لا يمكن أن تعلق في الحل الأمثل المحلي وإنما تستطيع الوصول إلى الحل الشامل.
- تعمل بشكل جيد في حل مشاكل التحسين واسعة النطاق.
- يمكن توظيفها في حل مشاكل التحسين المختلفة.

في حين تتجلى قيود الخوارزميات الجينية في:

- المشكلة في تحديد دالة اللياقة.
- كيفية تمثيل المشكلة.
- يوجد العديد من البارامترات التي يجب تحديدها في أثناء برمجة الخوارزمية الجينية (GA) مثل: عدد الحلول، الطفرة، التزاوج وغيرها...
- لا يمكن أن تستخدم الانحدار.
- ليست جيدة في تحديد الحل الأمثل المحلي.
- من الممكن أن تواجه صعوبة في العثور على الحل الشامل الدقيق.

7.5.4. تطبيقات الخوارزميات الجينية [21]


فيما يأتي بعض التطبيقات التي تستخدم الخوارزميات الجينية (GA):

- التنبؤ وتحليل بيانات الأنظمة الديناميكية غير الخطية.
- تخطيط مسار الروبوت.
- التخطيط الاستراتيجي.
- إيجاد شكل جزيئات البروتين.
- جدولة تسلسل العمليات.
- إنشاء الصور المتعددة.
- التحكم مثل: خط أنابيب الغاز.
- في مجال الطيران تستخدم للتهرب من الصواريخ.
- في مجال التصميم: أشباه الموصلات، الطائرات، شبكات الاتصال.
- في عمليات الجدولة: تسهيل عمليات الجدولة، والتصنيع وتوزيع الموارد.
- علم الآلة: تصميم الشبكات العصبونية بالكامل من حيث هيكلتها وأوزانها، تحسين خوارزميات التصنيف.
- معالجة الإشارة.

6.4. الانحدار الخطي

يُعرّف الانحدار الخطي بأنه من خوارزميات علم الآلة الخاضع للإشراف. يوفر علاقة خطية بين متغير مستقل ومتغير تابع للتنبؤ بنتائج الأحداث المستقبلية كما هو مبين في الشكل (18.4)، كما يُعدّ طريقة إحصائية تستخدم في علم البيانات وعلم الآلة للتحليل التنبؤي. يقوم نموذج الانحدار الخطي بالتنبؤ بقيمة المتغير التابع وهو المتغير الذي يتم تحليله أو دراسته بالاعتماد على المتغير المستقل [15].

الانحدار الخطي يحاكي العلاقة الرياضية بين المتغيرات ويقوم بالتنبؤ بالمتغيرات المستمرة أو الرقمية مثل المبيعات والراتب والعمر وسعر المنتج وما إلى ذلك. تكون طريقة التحليل هذه مفيدة عندما يتوفر متغيران على الأقل في البيانات، كما لوحظ في تنبؤات سوق الأوراق المالية، التحليل العلمي، وما إلى ذلك.




الشكل (18.4): العلاقة الخطية بين المتغير المستقل والمتغير التابع [24]

إذ إنَّ:

X : المتغير المستقل (الدخل)

Y : المتغير التابع (الخرج)

وفي الانحدار الخطي تُرسم مستقيمات عدة لنقاط البيانات المعيّنة كما في الشكل (19.4)، والهدف من خوارزمية الانحدار الخطي هو العثور على أفضل مستقيم يربط بين المتغير المستقل والمتغير التابع، ويطلق على هذا المستقيم "أفضل خط مناسب".



الشكل (19.4): المستقيمات التي تربط بين المتغير المستقل والمتغير التابع [24]

1.6.4. الفوائد الرئيسية للانحدار الخطي [24]

الانحدار الخطي هو أداة إحصائية شائعة الاستخدام في علم البيانات، وذلك بفضل الفوائد العديدة التي يوفرها مثل:

- سهولة التنفيذ

يُعدّ الانحدار الخطي سهل التطبيق حسابياً ولا يتطلب كثيراً من الخبرة الهندسية.

- التفسير

بخلاف النماذج الأخرى في التعلم العميق (الشبكات العصبونية)، فإنّ الانحدار الخطي واضح نسبياً ويجعل هذا النموذج يتفوّق على نماذج الصندوق الأسود⁵ التي تقتصر إلى التبرير حول المتغير الذي يتسبب في تغيير المتغير الناتج.

- قابلية التوسع

الانحدار الخطي عملية حسابية بسيطة وليست معقّدة ومن ثم يناسب الحالات التي تتطلب بيانات ضخمة جداً.

- الحساب في وقت قياسي

يمكن تدريب النموذج وإعادة تدريبه مع كل مثال جديد لتوليد توقعات في الوقت القياسي، على عكس الشبكات العصبونية التي تتطلب حسابات كثيرة ووقتاً كبيراً لإعادة التدريب على مجموعة بيانات جديدة، ومن ثم كل هذه العوامل تجعل من هذه النماذج الحسابية مكلفة وغير مناسبة لتطبيقات الوقت القياسي.

⁵ خوارزميات الصندوق الأسود في الذكاء الصنعي هي نماذج تعتمد على علم الآلة واتخاذ القرارات بناءً على البيانات، دون فهم عميق لعملية النموذج أو تفسيرها بسهولة.

2.6.4. أنواع الانحدار الخطي

1.2.6.4. الانحدار الخطي البسيط

يُعبّر الانحدار الخطي البسيط عن العلاقة بين متغير مستقل ومتغير تابع، مثل: العلاقة بين التلوث وارتفاع الحرارة. يُحدّد الانحدار الخطي علاقة خطية بين المتغيرات x, y والتي توضح العلاقة بين هذين المتغيرين. يُمثّل الانحدار الخطي بشكل مستقيم مائل كما هو موضح بالشكل (18.4) ويكون الهدف هو تحديد أفضل مستقيم يُناسب جميع البيانات.

رياضياً الانحدار الخطي يُمثّل بالمعادلة الآتية:

$$Y(x) = p_0 + p_1 * x \dots (7.4)$$

إذ:

X : في علم الآلة يُطلق عليه مُتغير المدخلات، في حين في الإحصاء يُطلق عليه المُتغير المُستقل. يُمثّل المُدخلات التي تُعطى للنموذج.

Y : المُتغير التابع (الخرج)، وهو المُتغير الذي يحاول النموذج التنبؤ به.

p_1 : معامل الانحدار، في الإحصاء يطلق عليه ميل الخط المُستقيم الأكثر ملاءمة لنموذج الانحدار.

2.2.6.4. الانحدار الخطي المتعدد

يُنشئ علاقة بين المتغيرات المستقلة (2 أو أكثر) والمتغير التابع. يمكن أن تكون المتغيرات المستقلة مستمرة أو فئوية، هذا النوع يساعد في القدرة على التنبؤ بالتغيرات المحتملة في المجتمع أو السوق أو الصناعة.

معادلة الانحدار الخطي المتعدد تشبه معادلة الانحدار الخطي البسيط، بالإضافة إلى المدخلات للمتغيرات الأخرى والمعادلة التي تمثل الانحدار الخطي المتعدد هي:

$$Y(x) = p_0 + p_1 * x + p_2 * x_2 + \dots + p(n) * x(n) \dots (8.4)$$

إلى جانب وظيفة التنبؤ، يستخدم نموذج الانحدار دالة الخسارة Loss function لتحسين معامل الانحدار (p_i) . دالة الخسارة للانحدار الخطي هي متوسط الخطأ التربيعي (MSE). بشكل أساسي تقيس MSE متوسط الفرق التربيعي بين القيم الفعلية والمتوقعة، والهدف هنا هو تقليل MSE لتعزيز دقة نموذج الانحدار.

$$\sum_{n=1}^k \frac{(Actual - predicted)^2}{k} \dots (9.4)$$

3.2.6.4. الانحدار اللوجستي

يُعدُّ الانحدار اللوجستي مناسباً في الحالات التي تحتوي على متغير تابع واحد يعتمد على مُتغيرات عدة مستقلة. الفرق الأساسي بين الانحدار اللوجستي والانحدار المتعدد يكمن في أن المتغير التابع في الانحدار اللوجستي يكون بشكل ثنائي (Binary).

7.4. شجرة القرار Decision Tree

تُعدّ خوارزمية شجرة القرار من خوارزميات علم الآلة الخاضع للإشراف، وعلى عكس خوارزميات علم الآلة الأخرى الخاضع للإشراف يمكن استخدام خوارزمية شجرة القرار لحل مشاكل الانحدار والتصنيف.

1.7.4. المصطلحات المستخدمة في شجرة القرار [11]

شجرة القرار لديها مصطلحات خاصة بها تتضمن العديد من المصطلحات المستمدة من الشجرة كما هو مبين بالشكل (20.4) وأهم هذه المصطلحات:

(1) عُقدة الجذر Root node: تُمثّل العينة الكلية أو العدد الكلي ثم يتم تقسيمها إلى مجموعتين أو أكثر متجانسة.


(2) التقسيم Splitting: هذه العملية تستخدم لتقسيم العقد إلى عقد فرعية اثنين أو أكثر.

(3) عُقدة القرار Decision node: العقد الناتجة من عملية تقسيم العقد الإضافية إلى عقد إضافية أخرى تسمى عُقدة القرار.

(4) العُقدة النهائية Leaf/ Terminal Node: العقد التي لا يمكن تقسيمها إلى عقد فرعية إضافية تُعرف باسم "العقدة النهائية".

(5) التقليم Pruning: العملية التي يتم فيها إزالة العقد الفرعية لعقدة القرار تُعرف باسم التقليم Pruning وهي عملية معاكسة لعملية التقسيم Splitting.

(6) الغصن Branch / Sub-Tree: كما يوحي الاسم وهو الجزء الفرعي من الشجرة الكاملة.



الشكل (20.4): المصطلحات الخاصة بشجرة القرار [23]

2.7.4. آلية عمل شجرة القرار

أولاً تُقسم البيانات بحسب أكبر عامل له تأثير على الخرج والتي تُسمى بعقدة الجذر. ثم يُحسب متوسط هذه القيم (وتُعدّ القيمة التي تنبأت بها الشجرة) ثم تتم مقارنة القيمة الحقيقية لكل عينة ضمن المجموعة مع المتوسط (القيمة التي تنبأت بها شجرة القرار). ومن ثم يُحسب متوسط الخطأ التربيعي MSE لكل العينات ضمن


المجموعة، وفي المرحلة التالية تُقسّم المجموعة الأولى إلى مجموعة أصغر بإدخال عامل آخر ثم حساب متوسط هذه القيم ومقارنة كل عينة مع المتوسط وحساب MSE بين القيم الحقيقية وقيمة المتوسط وبمتابعة عملية التقسيم والتكرار حتى الوصول الى أقل نسبة خطأ MSE، وتُسمى العقدة القابلة للانقسام بعقدة القرار، وتحتوي كل عقدة قرار شرط والعقدة النهائية غير القابلة للانقسام تُسمى بالعقدة النهائية وهي التي تحتوي قيمة الخرج.

3.7.4. أنواع شجرة القرار

يمكن أن تُصنّف شجرة القرار بحسب نوع المتغير الهدف، ومن ثم يمكن تصنيفها إلى نوعين:

1.3.7.4. شجرة القرار للمتغيرات الفئوية

تُعرف شجرة القرار الفئوية بأنها شجرة القرار التي يكون فيها المتغير الهدف فئوياً مثل: الجنس: ذكر أو أنثى وهكذا...، وتسمى شجرة التصنيف Classification Tree كما هو مبين بالشكل رقم (21.4).




الشكل (21.4): شجرة التصنيف [23]

2.3.7.4. شجرة القرار للمتغيرات المستمرة

إذا كان المتغير الهدف للشجرة هو متغير مُستمر (المتغيرات المستمرة هي المتغيرات العددية التي لها عدد لا نهائي

من القيم بين أي قيمتين)، مثل: العمر - الطول - الارتفاع وغيرها... وتسمى شجرة الانحدار Regression

Tree، والشكل رقم (22.4) يبين شجرة الانحدار.



الشكل (22.4): شجرة الانحدار [23]

4.7.4. مميزات شجرة القرار [23]

(1) سهولة الفهم

حتى بالنسبة لأولئك الذين ليس لديهم خلفية تحليلية فإن خوارزمية شجرة القرار سهلة جداً في الفهم. لا يحتاج المستخدم إلى أي معرفة إحصائية أو معلومات لدراسة الأشجار وقراءتها وتفسيرها. يمكن للمستخدمين قراءة البيانات بسهولة في أشجار القرار، إذ يتميز تمثيلها بالبساطة والسهولة في الاستخدام.

(2) مُفيدة في عملية استكشاف البيانات

يُعتقد أن شجرة القرار إذا لم تكن الأسرع، فإنها بالتأكيد واحدة من أسرع الطرق لتحديد المتغير الأكثر أهمية بالإضافة إلى تحديد العلاقة بين متغيرين أو أكثر. يمكن لشجرة القرار مساعدة المستخدمين في إنشاء متغيرات وميزات جديدة، وستتمتع هذه الميزات الجديدة بقوة أكبر في التنبؤ بالمتغير الهدف، كما يمكن استخدامها في عملية استكشاف البيانات.

(3) غير مقيدة

شجرة القرار هي خوارزمية متعددة الاستخدامات، ويمكنها التعامل مع المتغيرات الفئوية والمستمرة بسهولة ومن ثم فإن نوع البيانات ليس عاملاً مقيداً في هذه الخوارزمية.

8.4. الغابة العشوائية Random Forest

وهي من خوارزميات علم الآلة الخاضع للإشراف، وتعتمد على دمج نتائج العديد من أشجار القرار للوصول إلى نتيجة واحدة. يعود سبب انتشارها ومرونتها إلى قدرتها على التعامل مع مشكلات التصنيف Classification والانحدار Regression، وهي تُستخدم في مجالات عدة منها: البنوك والتجارة الإلكترونية لتوقع السلوكيات والنتائج [15].

تستخدم الغابة العشوائية تقنية Ensemble Learning⁶ لتقديم حلول للمشاكل المعقدة، ويتم تدريب الغابة العشوائية باستخدام bagging أو bootstrap aggregating وهي من خوارزميات علم الآلة المصممة لتحسين ثبات ودقة خوارزميات علم الآلة المستخدمة في التصنيف والانحدار. تنتج الخوارزمية نتائجها استناداً إلى توقعات أشجار القرار، وتقوم بالتنبؤ عن طريق أخذ المتوسط الحسابي للنتائج المتعددة التي تم إنتاجها من الأشجار المختلفة، وبزيادة عدد الأشجار تزداد دقة النتائج [26].

تستطيع الغابة العشوائية Random Forest أن تُزيل القيود المفروضة على خوارزمية شجرة القرار مثل: Overfitting⁷، وتزيد من الدقة كونها طريقة تجميعية Ensemble Method تجمع بين العديد من أشجار القرار لإنتاج نموذج أكثر دقة واستقراراً على عكس شجرة القرار الفردية.

1.8.4. الفرق بين شجرة القرار والغابة العشوائية

الفرق الرئيسي بين خوارزمية شجرة القرار وخوارزمية الغابة العشوائية هو أنه في الغابة العشوائية تتم عملية إنشاء عقدة الجذر وعملية انقسام العقد عشوائياً. تستخدم الغابة العشوائية طريقة bagging لتوليد التنبؤ المطلوب وتتضمن خوارزمية bagging استخدام عينات مختلفة من البيانات (بيانات التدريب) بدلاً من عينة

⁶ تقنية في مجال الذكاء الصناعي تهدف إلى تحسين أداء النماذج عن طريق دمج مجموعة من النماذج الفردية، وهذه النماذج الفردية يتم تدريبها بشكل مستقل.


⁷ تعلم نماذج الذكاء الصناعي بشكل مفرط على بيانات التدريب ولكنها تُظهر أداء ضعيفاً على بيانات جديدة غير مألوقة

واحدة فقط وتشمل مجموعة بيانات التدريب الملاحظات والميزات المستخدمة في إجراء التنبؤات. في الغابة العشوائية تنتج أشجار القرار مخرجات مختلفة اعتماداً على بيانات التدريب التي يتم تغذيتها لخوارزمية الغابة العشوائية ثم يتم اختيار التنبؤ النهائي بناءً على نتيجة الأشجار الكلية.

2.8.4. أنواع الغابة العشوائية

1.2.8.4. الغابة العشوائية للتصنيف


تعتمد الغابة العشوائية على منهجية تجميع العديد من أشجار القرار للحصول على النتيجة إذ يتم تغذية بيانات التدريب لتدريب مجموعة متنوعة من أشجار القرار. يتكوّن هذا النموذج من مجموعة من المشاهدات والميزات التي يتم اختيارها عشوائياً في أثناء تقسيم العقد، وتتكوّن كل شجرة قرار من عقد الجذر وعقدة القرار والعقدة النهائية. العقدة النهائية في كل شجرة هي الناتج النهائي الذي يُنتج بواسطة شجرة القرار الخاصة. يتم اختيار الناتج النهائي باستخدام نظام التصويت الأغلب، وفي هذه الحالة يصبح الإخراج الذي اختارته غالبية أشجار القرار هو الإخراج النهائي للغابة، كما هو مبين في الشكل (23.4).



الشكل (23.4): الغابة العشوائية للتصنيف [25]

2.2.8.4. الغابة العشوائية للانحدار

يُعد الانحدار هو المهمة الأخرى التي يمكن القيام بها بواسطة الغابة العشوائية. تتبع الغابة العشوائية للانحدار مفهوم الانحدار البسيط، إذ يتم تمرير المتغيرات المستقلة والتابعة للغابة. في الغابة العشوائية للانحدار تنتج كل شجرة تنبؤاً محدداً، ومتوسط التنبؤ بالأشجار الفردية هو ناتج الانحدار كما هو مبين بالشكل رقم (24.4).



الشكل (24.4): الغابة العشوائية للانحدار [25]

3.8.4. ميزات خوارزمية الغابة العشوائية [26]

- (a) أكثر دقة من خوارزمية شجرة القرار .
- (b) يمكنها أداء مهام الانحدار والتصنيف.
- (c) تُنتج تنبؤات جيدة والتي يمكن فهمها بسهولة.
- (d) يمكنها التعامل مع البيانات الضخمة.
- (e) توفر طريقة فعالة للتعامل مع البيانات المفقودة.
- (f) تحل مشكلة overfitting الموجودة في شجرة القرار .
- (g) في كل شجرة، يتم اختيار مجموعة فرعية من الميزات عشوائياً عند نقطة انقسام العقدة.

9.4. الخلاصة

في هذا الفصل كان من الضروري التعرف إلى خوارزميات الذكاء الصنعي (الشبكات العصبونية، الخوارزميات الجينية، الانحدار الخطي، شجرة القرار، الغابة العشوائية) وشرح آلية عملها ومميزاتها ومساوئها إذ استُخدمت في الجزء العملي من هذا البحث وأُجريت مقارنة بينها للحصول على أفضل نموذج للتنبؤ بخشونة السطح، واستُخدمت الخوارزميات الجينية للحصول على الحل الأمثل.

الفصل الخامس: القسم العملي

1.5. مقدمة

يشتمل هذا الفصل على وصف للأجهزة المستخدمة لإجراء البحث والخطوات التي تُفُتد للحصول على النتائج، ثم استُخدمت هذه النتائج لبناء خوارزميات عدة للتنبؤ بخشونة السطح، وبعد ذلك أُجريت مقارنة بين أداء هذه الخوارزميات لاختيار أفضل نموذج وللحصول على الحل الأمثل استُخدمت الخوارزميات الجينية.

2.5. تجهيز العينات

1.2.5. اختيار المعدن للتشغيل

استُخدم فولاذ AISI 1040 وهو فولاذ متوسط نسبة الكربون ويتمتع بخصائص جيدة، كما هو مبين في كلٍ من الجدول (1.5)، (2.5) مع إمكانية تشغيله بسهولة. هذه الخصائص تجعل من هذا الفولاذ مناسباً للعديد من التطبيقات مثل: مسننات، محاور، عمود المرفق (الكرنك)، الوصلات، المحامل، وغيرها من التطبيقات العديدة.

الجدول (1.5): التركيب الكيميائي للمعدن

C	Si	Mn	Cr	Mo	Ni	V	W	others
0.41	Max 0.40	0.65	Max 0.40	Max 0.1	Max 0.4	-	-	=Cr+Mo+Ni Max0.63

الجدول (2.5): خصائص المعدن

Tensile strength	620 MPa
Yield strength	415 MPa
Hardness, Brinell	201
Density [g/cm ³]	7.84
Modulus of elasticity (GPa)	210

2.2.5. اختيار اللقمة المستخدمة

لقمة كربيدية NM4 - DNMG 110408 ألمانية الصنع من صنع شركة Walter والموضحة بالشكل (1.5)



الشكل (1.5): اللقمة المستخدمة

3.2.5. اختيار البارامترات

اختيرت هذه البارامترات والمبينة بالجدول (3.5) بحسب المعدن المستخدم واللقمة المستخدمة [27]. حدود المدخلات هي: سرعة الدوران من القيمة 1274 إلى 3822 ومعدل التغذية من القيمة 0.18 إلى 0.25 في حين عمق القطع من القيمة 0.6 إلى 1. حُصِل على العينات الموجودة في الجدول (4.5) من خلال الآتي: تُثبت سرعة الدوران عند 1274 ومعدل التغذية عند 0.18 وبتغيير عمق القطع إذ كان في العينة الأولى عمق القطع

0.6، وفي العينة الثانية 0.8، وفي العينة الثالثة 1، وبهذه الحالة حُصل على 3 عينات، بعد ذلك تُثبت سرعة الدوران عند 1274 ومعدل التغذية عند 0.21، وبتغيير عمق القطع إذ يكون في العينة الرابعة 0.6، وفي العينة الخامسة عمق القطع 0.8 وفي العينة السادسة 1، ثم بعد ذلك تُثبت سرعة الدوران عند 1274 ومعدل التغذية عند 0.25 وبتغيير عمق القطع إذ يكون في العينة السابعة 0.6 وفي العينة الثامنة 0.8 وفي العينة التاسعة 1 ثم تُثبت سرعة الدوران عند 2548 ومعدل التغذية عند 0.18 وبتغيير عمق القطع إذ يكون في العينة العاشرة 0.6 وفي العينة الحادية عشرة 0.8 وفي العينة الثانية عشرة 1، وهكذا حتى الحصول على 27 عينة مقسمة على 7 قطع تحتوي كل قطعة على عینتين فقط من كل طرف إذ بزيادة عدد العينات بالقطعة الواحدة من الممكن أن يحصل اهتزاز في أثناء عمليات التشغيل والذي يسبب خطأ في دقة القياس والذي بدوره يؤثر في دقة التنبؤ بخشونة السطح باستخدام نموذج الذكاء الصناعي بالمستقبل.

الجدول (3.5): بارامترات القطع


بارامترات القطع	مرحلة 1	مرحلة 2	مرحلة 3
سرعة الدوران (r.p.m)	1274	2548	3822
معدل التغذية (mm\rev)	0.18	0.21	0.25
عمق القطع (mm)	0.6	0.8	1

الجدول (4.5): بارامترات القطع الموافقة لكل عينة

رقم العينة	سرعة الدوران r.p.m	معدل التغذية mm/rev	عمق القطع mm
1	1274	0.18	0.6
2	1274	0.18	0.8
3	1274	0.18	1
4	1274	0.21	0.6
5	1274	0.21	0.8
6	1274	0.21	1
7	1274	0.25	0.6
8	1274	0.25	0.8
9	1274	0.25	1
10	2548	0.18	0.6
11	2548	0.18	0.8
12	2548	0.18	1
13	2548	0.21	0.6
14	2548	0.21	0.8
15	2548	0.21	1
16	2548	0.25	0.6
17	2548	0.25	0.8
18	2548	0.25	1
19	3822	0.18	0.6
20	3822	0.18	0.8
21	3822	0.18	1
22	3822	0.21	0.6
23	3822	0.21	0.8
24	3822	0.21	1
25	3822	0.25	0.6
26	3822	0.25	0.8
27	3822	0.25	1

4.2.5. رسم القطعة


رُسمت القطعة على برنامج solidworks والمبينة بالشكل (2.5) إذ بلغ طول القطعة 150 mm والقطر 25 mm وكل عينة بطول 20 mm، إذ تحتوي كل قطعة على 4 عينات: عينتان من كل طرف.



الشكل (2.5): رسم القطعة على برنامج solidworks

5.2.5. استخراج G-code

استُخدم برنامج Vero Surfcam 2014 R2 والمبين بالشكل (3.5) لمحاكاة عملية الخراطة واستخراج G-code التي نُقلت إلى المخرطة المستخدمة للتشغيل. G-codes للعينة رقم 2+1 (الملحق رقم 1).




الشكل (3.5): إجراء عملية الخراطة على برنامج Vero Surfcam

6.2.5. تشغيل العينات على المخرطة

استُخدمت مخرطة من نوع VICTOR TAICHUNG الموجودة في كلية الهندسة الميكانيكية والكهربائية _ جامعة دمشق ويبين كلٌّ من الشكلين (4.5)، (5.5) المخرطة المستخدمة.



الشكل (4.5): المخرطة المستخدمة



الشكل (5.5): المخرطة مع توضع العينة

العينة



الشكل (6.5): العينات بعد إجراء عملية الخراطة

7.2.5. قياس خشونة العينات

استُخدم جهاز قياس خشونة السطح من نوع TR200 الموجود في كلية الهندسة الميكانيكية والكهربائية_ جامعة دمشق

مبدأ عمل الجهاز:

في أثناء إجراء القياس، يتحرك المستشعر خطياً على طول الجزء المقاس ثم يتم تحويل هذه الحركات إلى إشارات كهربائية يتم تضخيمها، ثم يتم تصفيتها وتحويلها إلى إشارات رقمية بوساطة محول A/D. ثم يتم تنقيح هذه الإشارات في المعالج الرئيسي باسم R_a . ويبين الشكل (7.5) جهاز TR200 في أثناء قياس خشونة العينات بعد إجراء عملية الخراطة عليها.

نطاق قياس الجهاز: $R_a: 0.005 - 16 \mu m$



الشكل (7.5): جهاز قياس الخشونة

العينة

الجهاز

الجدول (5.5): نتائج قياس خشونة السطح للعينات


رقم العينة	سرعة الدوران r.p.m	معدل التغذية mm\rev	عمق القطع mm	خشونة السطح R_a μm
1	1274	0.18	0.6	2.63
2	1274	0.18	0.8	2.622
3	1274	0.18	1	2.628
4	1274	0.21	0.6	3.638
5	1274	0.21	0.8	3.647
6	1274	0.21	1	3.586
7	1274	0.25	0.6	5.103
8	1274	0.25	0.8	5.144
9	1274	0.25	1	5.175
10	2548	0.18	0.6	2.647
11	2548	0.18	0.8	2.641
12	2548	0.18	1	2.618
13	2548	0.21	0.6	3.663
14	2548	0.21	0.8	3.593
15	2548	0.21	1	3.604
16	2548	0.25	0.6	5.165
17	2548	0.25	0.8	5.146
18	2548	0.25	1	5.158
19	3822	0.18	0.6	2.694
20	3822	0.18	0.8	2.644
21	3822	0.18	1	2.616
22	3822	0.21	0.6	3.501
23	3822	0.21	0.8	3.555
24	3822	0.21	1	3.598
25	3822	0.25	0.6	5.021
26	3822	0.25	0.8	5.166
27	3822	0.25	1	5.066

3.5. دراسة تأثير بارامترات القطع في خشونة السطح

لمعرفة تأثير كل بارامتر في خشونة السطح تُثبتت البارامترات الأخرى ويتغير هذا البارامتر من خلال الآتي:

1.3.5. دراسة تأثير سرعة الدوران في خشونة السطح

عندما تُثبت عمق القطع عند 0.6 ومعدل التغذية عند 0.18 يُلاحظ أنه بزيادة سرعة الدوران تزداد خشونة السطح، وكذلك الأمر عندما تُثبت عمق القطع عند 0.8 ومعدل التغذية عند 0.18 يُلاحظ أنه بزيادة سرعة الدوران تزداد خشونة السطح في حين عندما تُثبت عمق القطع عند 1 ومعدل التغذية عند 0.18 يُلاحظ بزيادة سرعة الدوران تنخفض الخشونة كما هو مبين بالشكل (8.5).




الشكل (8.5): العلاقة بين سرعة الدوران وخشونة السطح

ومن خلال ماسبق استنتج أن العلاقة بين سرعة الدوران وخشونة السطح هي علاقة مُتغيرة.

2.3.5. دراسة تأثير عمق القطع في خشونة السطح

تُثبت سرعة الدوران عند 1274 ومعدل التغذية عند 0.21 ولُوحظ أنه بزيادة عمق القطع تزداد الخشونة ثم تعود للانخفاض، في حين عندما تُثبت سرعة الدوران عند 2548 ومعدل التغذية عند 0.21 لُوحظ أنه بزيادة عمق القطع تنخفض الخشونة ثم تعود للارتفاع، في حين عندما تُثبت سرعة الدوران عند 3822 ومعدل التغذية عند 0.21 لُوحظ أنه بزيادة عمق القطع تزداد الخشونة، كما هو مبين بالشكل (9.5).




الشكل (9.5): العلاقة بين عمق القطع وخشونة السطح

ومن ثم استنتج أن العلاقة بين عمق القطع وخشونة السطح هي علاقة مُتغيرة.

3.3.5. دراسة تأثير معدل التغذية في خشونة السطح

تُثبت سرعة الدوران عند 1274 وعمق القطع عند 0.6 ولُوحظ أنه بزيادة معدل التغذية تزداد خشونة السطح، وكذلك عندما تُثبت سرعة الدوران عند 1274 وعمق القطع عند 0.8 لُوحظ أنه بزيادة معدل التغذية تزداد خشونة السطح، وكذلك عندما تُثبت سرعة الدوران عند 1274 وعمق القطع عند 1 لُوحظ أنه بزيادة معدل التغذية تزداد خشونة السطح، كما هو مبين بالشكل (10.5).



الشكل (10.5): العلاقة بين معدل التغذية وخشونة السطح

ومن ثم العلاقة بين معدل التغذية وخشونة السطح هي علاقة خطية إذ بزيادة معدل التغذية تزداد خشونة السطح.


4.5. خوارزميات الذكاء الصنعي

في جميع خوارزميات الذكاء الصنعي استُخدمت لغة برمجة بايثون Python لما لها من أهمية كبيرة في مجال الذكاء الصنعي ولاحتوائها على مكتبات كثيرة والتي بدورها تُسهل تنفيذ هذه الخوارزميات بكل سهولة. استُخدم Pycharm الشكل رقم (11.5) وهو محرر بيئة تطوير متكاملة مُخصَّص للغة Python وله العديد من الميزات والأدوات المفيدة مثل: الإكمال التلقائي للكود، تحليل الأخطاء، التصحيح السريع، وغيرها الكثير من الميزات. قُسمت الخوارزميات التي استُخدمت في هذه الرسالة إلى خوارزميات التنبؤ وخوارزميات الحل الأمثل والمبينة بالشكل (12.5).

في جميع خوارزميات الذكاء يجب تقسيم البيانات إلى عينات تدريب التي يتم تدريب النموذج عليها، وعينات تقييم لتقييم أداء النموذج في أثناء عملية التدريب، وعينات اختبار لاختبار أداء النموذج بعد عملية التدريب إذ قُسمت العينات من الجدول (5.5) إلى 80% عينات تدريب و20% عينات اختبار، وعينات التدريب قُسمت إلى 90% للتدريب و10% لتقييم النموذج كما ذُكر في [16].



الشكل (11.5): برنامج Pycharm




الشكل (12.5): خوارزميات الذكاء الصنعي

1.4.5. خوارزميات التنبؤ

1.1.4.5. الانحدار الخطي


يوفر الانحدار الخطي علاقة خطية بين المتغيرات المستقلة (سرعة الدوران، معدل التغذية، عمق القطع) والمتغير التابع (خشونة السطح) إذ قام برسم مستقيمات عدة تربط بين المتغيرات المستقلة والمتغير التابع ثم قام باختيار أفضل مستقيم. الكود البرمجي (الملحق رقم 2) الذي يبين كيفية برمجة الانحدار الخطي. حُسب متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الاختبار (6 عينات) أي الفرق بين القيم الحقيقية لخشونة السطح من الجدول (5.5) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته $MSE = 0.00856$ ، والشكل (13.5) يبين كل عينة مع خشونة السطح الموافق لها، وكذلك يبين مدى التطابق بين القيم الحقيقية الموجودة على الشكل باسم "Actual" والقيم المتنبأ بها بواسطة الخوارزمية والموجودة على الشكل باسم "Predicted".




الشكل (13.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الانحدار الخطي

2.1.4.5. شجرة القرار

تقوم شجرة القرار بتقسيم العينات كما هو واضح بالشكل (14.5) بحسب أكبر عامل له تأثير في الخرج، وهنا معدل التغذية وقد اعتُبر كعقدة للجذر، والشرط في عقدة الجذر هو $0.23 \leq$ معدل التغذية، ثم تقوم بحساب متوسط هذه القيم وعدّها قيمة تنبؤ للشجرة ثم مقارنة هذه القيمة بالقيمة الحقيقية لكل عينة وحساب متوسط الخطأ للتربيعي لكل العينات MSE، ثم تُقسم هذه المجموعة إلى مجموعة أصغر بإدخال عامل آخر من الشكل (14.5) ادخل 3185 $\leq$ سرعة الدوران (الجزء اليميني من الشجرة) أو $0.195 \leq$ معدل التغذية (الجزء اليساري من الشجرة). وهذه العقد تدعى عقدة قرار كونها قابلة للانقسام، وتحتوي على شرط ثم تقوم الشجرة بحساب متوسط هذه القيم (قيمة التنبؤ للشجرة) ومقارنتها مع القيمة الحقيقية لكل عينة ثم حساب MSE، ثم تُقسم هذه المجموعات إلى مجموعات أصغر (بإدخال شروط جديدة) حتى الوصول إلى أقل نسبة خطأ والعقد النهائية غير القابلة للانقسام تُدعى بالعقد النهائية وهي التي تُعطي قيمة الخرج (التنبؤ). الكود البرمجي (الملحق رقم 3) الذي يبين كيفية برمجة شجرة القرار. حُسب متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الاختبار (6 عينات) أي الفرق بين القيم الحقيقية لخشونة السطح من الجدول (5.5) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته $MSE = 0.00574$. الشكل (15.5) يبين كل عينة مع خشونة السطح الموافقة لها، وكذلك يبين مدى التطابق بين القيم الحقيقية الموجودة على الشكل باسم "Actual" والقيم المتنبأ بها بواسطة الخوارزمية والموجودة على الشكل باسم "Predicted".



الشكل (14.5): هيكل شجرة القرار




الشكل (15.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام شجرة القرار


3.1.4.5. الغابة العشوائية

الكود البرمجي (الملحق رقم 4) الذي يبين كيفية برمجة الغابة العشوائية. وكما ذكر سابقاً تقوم الغابة العشوائية بالتنبؤ عن طريق أخذ المتوسط الحسابي للنتائج المتعددة من الأشجار المختلفة، وبزيادة عدد الأشجار تزداد دقة النتائج إذ استخدمت 10 أشجار في الغابة، وبعد زيادة عدد الأشجار عن 10 لم يلاحظ أي تحسن في دقة النموذج. الشكل (16.5) يبين الشجرة الأولى والشكل (17.5) يبين الشجرة الثانية، ويمكن استخراج الأشجار كافة الموجودة في الغابة. حُسِبَ متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الاختبار (6 عينات) أي الفرق بين القيم


الحقيقية لخشونة السطح من الجدول (5.5) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته $MSE = 0.00472$. الشكل (18.5) يبين كل عينة مع خشونة السطح الموافقة لها، وكذلك يبين مدى التطابق بين القيم الحقيقية الموجودة على الشكل باسم "Actual" والقيم المتنبأ بها بواسطة الخوارزمية والموجودة على الشكل باسم "Predicted".



الشكل (16.5): الشجرة الأولى



الشكل (17.5): الشجرة الثانية



الشكل (18.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الغابة العشوائية

4.1.4.5. الشبكة العصبونية

استُخدمت مكتبة Keras⁸ ضمن برنامج Pycharm.

الشبكة العصبونية التي بُنيت (الشكل رقم 19.5) تتألف من:

طبقة المدخلات: وتحتوي على 3 عصبونات وهي بارامترات القطع (سرعة الدوران، معدل التغذية، عمق القطع) في حين الطبقة المخفية: استُخدمت طبقة مخفية واحدة فقط وتحتوي على 300 عصبون إذ حُدِد عدد العصبونات من خلال التجريب وهي عملية استغرقت كثيراً من الوقت إذ جُرِّب عدد معين من العصبونات، ثم دُرِّبَت الشبكة على هذا العدد من العصبونات، ثم حُسبت نسبة الخطأ الناتج من اختيار هذا العدد، وبعد ذلك عُدِّل عدد العصبونات

⁸ مكتبة برمجية تُستخدم لتطوير الشبكات العصبونية وتسمح هذه المكتبة للمطورين ببناء الشبكة العصبونية وتدريبها بسهولة وببساطة.

وقيست نسبة الخطأ وهكذا ... وطبقة الخرج: المؤلف من عصيون واحد (خشونة السطح) تابع التفعيل (التنشيط): كما ذكر سابقاً أنَّ أهمية هذا التابع هي تحويل المدخلات إلى خرج إذ استُخدم تابع Relu ولُوحظ أن تابع Relu يعمل جيداً كتابع تنشيط.

تابع الخسارة: مهمة هذا التابع هو قياس نسبة الخطأ بين القيم الحقيقية والقيم المتنبأ بها (الناجمة من الخوارزمية) إذ استُخدم تابع MSE.

تابع التحسين: أهمية هذا التابع هو تعديل قيم الأوزان لتقليل نسبة الخطأ MSE وقد وُجد أن تابع SGD هو أفضل تابع (إذ جُرب العديد من التوابع ثم اختير أفضل تابع).


batch size: لُوحظ أن اختيار $\text{batch size} = 1$ أعطى أدق نموذج، أي تقوم الخوارزمية بتحديث الأوزان بعد كل عينة، في حين معدّل التعلّم: يحدّد سرعة أو بطء الوصول إلى الأوزان المثلى، وقد وُجد أن اختيار $\text{LearningRate} = 0.0001$ أعطى أدق نموذج، ولكن هنا في هذه الحالة احتاجت الشبكة إلى زمن طويل للوصول إلى أفضل الأوزان.

Epochs: عدد مرات التكرار وهي عدد مرات معالجة عينات التدريب كافة وقد اختير


$\text{Epochs} = 600,000$ وهو رقم كبير ولكن بسبب معدل التعلّم القليل فقد احتاجت الشبكة إلى عدد كبير من عدد مرات التكرار لتصل إلى أفضل دقة، ولُوحظ أن الشبكة استغرقت كثيراً من الوقت لانتهاء عملية التدريب.

الكود البرمجي للشبكة العصبونية (الملحق رقم 5). الشكل (20.5) يبين العلاقة بين عدد مرات التكرار (epochs) والخطأ (loss) إذ من الشكل لُوحظ أنه بازدياد عدد مرات التكرار تنخفض نسبة الخطأ (loss) ولكن بنسبة قليلة جداً. حُسب متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الاختبار (6 عينات) أي الفرق بين القيم الحقيقية لخشونة السطح من الجدول (5.5) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته $\text{MSE} = 0.00162$. الشكل (21.5) يبين كل عينة مع خشونة السطح الموافقة لها، وكذلك يبين مدى التطابق


بين القيم الحقيقية الموجودة على الشكل باسم "Actual" والقيم المتنبأ بها بواسطة الخوارزمية والموجودة على الشكل باسم "Predicted".



الشكل (19.5): الشبكة العصبونية المستخدمة



الشكل (20.5): العلاقة بين عدد مرات التكرار والخطأ



الشكل (21.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الشبكة العصبونية

5.1.4.5. الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية

استُخدمت مكتبة `Pygad`⁹ لتنفيذ الخوارزمية الجينية وجزء الشبكة نُفذ بواسطة مكتبة `Tensorflow`¹⁰. الشبكة

العصبونية المدربة بواسطة الخوارزمية الجينية التي بُنيت تحتوي على:

طبقة المدخلات: تحتوي على 3 عصبونات هي بارامترات القطع (سرعة الدوران، معدل التغذية، عمق القطع)،

طبقة مخفية: طبقة واحدة وتحتوي على 5 عصبونات، طبقة الخرج: عصبون واحد (خشونة السطح) وتابع

التفعيل: لُوحظ أن تابع `Relu` هو الأفضل. تابع الخسارة: استُخدم تابع `MSE`.

أما فيما يتعلق بالخوارزمية الجينية فآلية العمل بالشكل الآتي:

⁹ مكتبة برمجية مفتوحة المصدر للخوارزمية الجينية وتم تصميمها لتكون مكتبة سهلة الاستخدام ولحل مشاكل الأمثلة.

¹⁰ مكتبة مفتوحة المصدر تُستخدم في تطبيقات وعلم الآلة والشبكات العصبونية على نطاق واسع.

حُدِد عدد الأجيال 2000 جيل إذ لوحظ أنه بعد هذه القيمة لم تتحسن دقة النموذج وتم توليد 40 حلاً أي (40 شبكة عصبونية) في الجيل الواحد، أي في الجيل الأول تم توليد 40 حلاً (شبكة عصبونية) بشكل عشوائي تختلف هذه الشبكات عن بعضها بتتابع التحسين والأوزان ومعدل التعلّم وغيرها... ثم قُيِّمت هذه الحلول بحسب دالة اللياقة لاختيار الأنسب منها، وقد اختيرت باستخدام عجلة الروليت والتزاوج بين هذه الحلول استُخدم التزاوج في نقطة واحدة إذ باستخدام الطرق الأخرى انخفضت دقة النموذج وبذلك انتقلت أفضل الحلول من الجيل الأول إلى الجيل الثاني، وفي الجيل الثاني تم توليد 40 حلاً (شبكة عصبونية) جديدة بالإضافة إلى أفضل الحلول من الجيل الأول، ثم قيمت هذه الحلول لاختيار الأمثل منها ثم تتزاوج وهكذا حتى الوصول إلى الجيل 2000.

الكود البرمجي للشبكة العصبونية المدربة بواسطة الخوارزمية الجينية (الملحق رقم 6).

الشكل (22.5) يبين أنه بزيادة عدد الأجيال تزداد دقة النموذج. حُسب متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الاختبار (6 عينات)، أي الفرق بين القيم الحقيقية لخشونة السطح من الجدول (5.5) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته $MSE = 0.000446$. الشكل (23.5) يبين كل عينة مع خشونة السطح الموافقة لها، وكذلك يبين مدى التطابق بين القيم الحقيقية الموجودة على الشكل باسم "Actual" والقيم المتنبأ بها بواسطة الخوارزمية والموجودة على الشكل باسم "Predicted".


من خلال ماسبق لوحظ أن عملية بناء الشبكة العصبونية وتدريبها باستخدام الخوارزمية الجينية أعطت دقة أفضل كونها أعطت أقل قيمة خطأ (MSE)، وكذلك عملية البناء والتدريب استغرقت وقتاً أقل إذ في الشبكة العصبونية مثلاً وُجد أن عدد العصبونات الأمثل 300 وللوصول لهذه القيمة استغرق عملية تجريب وقياس نسبة الخطأ وهكذا حتى الوصول إلى هذا الرقم، في حين في الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية عدد العصبونات 5 فقط وفي الشبكة العصبونية حُدِد معدّل التعلّم بتجريب العديد من المحاولات حتى الوصول إلى أفضل رقم $LearningRate = 0.0001$ ، في حين في الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية لم يُحدّد هذا العامل، وكذلك بالنسبة لتابع التحسين في الشبكة العصبونية جُرّب العديد من

التتابع حتى الوصول للتابع الأمثل وهو SGD في حين في الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية لم يُحدّد هذا التابع وغيرها من العوامل التي تطلبت كثيراً من المحاولات.


وُجد أن الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية أيضاً تطلبت بعض العوامل التي احتاجت للتجريب مثل: عدد الأجيال، عدد الحلول في الجيل الواحد، وعملية اختيار الحلول وغيرها ولكن عملية التجريب في هذه الخوارزمية لم تتطلب كثيراً من الوقت بالمقارنة مع الشبكة العصبونية السابقة، وكذلك دقة الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية أفضل من الشبكة العصبونية.

الشكل (24.5) والشكل (25.5) يوضح الفرق بين الشبكة العصبونية والشبكة العصبونية المدربة بواسطة الخوارزمية الجينية مع القيم الحقيقية إذ لوحظ أن الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية تعطي انطباقاً شبه تام مع القيم الحقيقية، في حين أنه في الشبكة العصبونية وُجد اختلاف مع القيم الحقيقية.

ومن ثم فإنّ أفضل نموذج للتنبؤ بخشونة السطح هو الشبكة العصبونية المدربة بواسطة الخوارزمية الجينية، كما هو مبين بالجدول رقم (6.5).




الشكل (22.5): زيادة دقة النموذج بازدياد عدد الأجيال




الشكل (23.5): مدى التطابق بين القيم الحقيقية والقيم المتنبأ بها باستخدام الشبكة العصبونية المدربة بواسطة

الخوارزمية الجينية



الشكل (24.5): الفرق بين الشبكة العصبونية والشبكة العصبونية المدربة بواسطة الخوارزميات الجينية



الشكل (25.5): الفرق بين الشبكة العصبونية والشبكة العصبونية المدربة بوساطة الخوارزميات الجينية

الجدول (6.5): أفضل خوارزمية للتنبؤ بخشونة السطح

خوارزمية التنبؤ prediction algorithm	الانحدار الخطي Linear regression	شجرة القرار Decision tree	الغابة العشوائية Random forest	الشبكة العصبونية Neural networks	الشبكة العصبونية المُدْرَبَة بواسطة الخوارزمية الجينية NN-GA
متوسط الخطأ التربيعي MSE	0.00856	0.00574	0.00472	0.00162	0.000446

2.4.5. خوارزميات الحل الأمثل

1.2.4.5. الخوارزميات الجينية

في بعض الحالات يُطلب الحصول على أنعم سطح لذلك يجب معرفة بارامترات القطع (سرعة الدوران، معدل التغذية، عمق القطع) التي يجب إدخالها إلى المخرطة والتي تُعطي أنعم سطح، لذلك استُخدمت الخوارزميات الجينية للحصول على هذه البارامترات، ولكن في البداية يُطلب الحصول على المعادلة التي تربط بين هذه البارامترات مع خشونة السطح ومن ثم إدخالها إلى الخوارزمية لحلها.

استُخدم برنامج Minitab¹¹ لإيجاد العلاقة بين بارامترات القطع وخشونة السطح إذ أُعطي البرنامج العينات الموجودة في الجدول (5.5)، ثم قام بتوليد العديد من المعادلات منها ما هو خطي، تربيعي، تكعيبي واختير أفضل معادلة من بين المعادلات التي قام البرنامج بتوليدها التي أعطت أقل قيمة للخطأ وهي:

$$R_a = -3.545 + 0.000064 \times N + 34.69 \times F - 0.598 \times d - 0.000421 \times N \times F \\ + 0.000015 \times N \times d + 2.61 \times F \times d \quad \dots (1.5)$$

وهنا قُيِّمت الخوارزمية بثلاث حالات:

1. إيجاد بارامترات القطع التي تعطي أقل خشونة سطح ضمن المجال المُحدَّد للقيمة:

$$1274 \leq (N) \leq 3822 \text{ سرعة الدوران}$$

$$0.18 \leq (F) \leq 0.25 \text{ معدل التغذية}$$

$$0.6 \leq (d) \leq 1 \text{ عمق القطع}$$

استُخدمت مكتبة Pygad لتنفيذ الخوارزمية الجينية والكود البرمجي لتنفيذ الخوارزمية (الملحق رقم 7).


البارامترات التي حُدِّدت للخوارزمية الجينية هي:

¹¹ برنامج إحصائي يُستخدم لتحليل البيانات وتوليد الرسوم البيانية ويحتوي على واجهة بسيطة وسهلة الاستخدام ويُتيح للمستخدمين إدخال البيانات وتحليلها باستخدام مجموعة واسعة من التقنيات.

لُوحظ أن عدد الأجيال الأفضل هو 100,000 إذ إنه بعد زيادة هذا العدد لم يُلاحظ أي تحسُّن في حين عدد الحلول في الجيل الواحد هو 500 بزيادة هذه القيمة عن 500 لم يُلاحظ أي زيادة في دقة النموذج وعملية الاختيار. وُجد أن الاختيار عن طريق عجلة الروليت هو الأمثل في حين أنه في عملية التزاوج اختير التزاوج في نقطة واحدة والطفرة حُدِّدت لتكون بشكل عشوائي (أي تغيير بسيط في الحل) والتي بدورها من الممكن أن تُعطي حلاً أفضل.

آلية عمل الخوارزمية الجينية هي:

في الجيل الأول تم توليد 500 حل بشكل عشوائي ثم قُيِّمت هذه الحلول بحسب دالة اللياقة، واختير أفضل هذه الحلول باستخدام عجلة الروليت والحلول التي اختيرت تتزاوج في نقطة واحدة وعُدِّلت الحلول بشكل عشوائي لإجراء الطفرة، ثم انتقلت هذه الحلول للجيل الثاني وبإعادة الخطوات نفسها حتى الوصول للجيل 100,000. في هذه الحالة حُدِّدت قيمة الخشونة المُثلى الواجب على الخوارزمية الوصول إليها هي: 0.0000000000000001 أي للوصول لأنعم سطح، ولكن من الشكل (26.5) الذي يبين العلاقة بين عدد الأجيال وكفاءة النموذج، فقد لُوحظ أن كفاءة النموذج هي فقط 0.388.



الشكل (26.5): العلاقة بين عدد الأجيال وكفاءة النموذج

البارامترات الناتجة عن الخوارزمية هي:

سرعة الدوران (N): 1274 r.p.m

معدل التغذية (F): 0.18 mm/rev

عمق القطع (d): 0.9 mm

ولتقييم هذه البارامترات أُجريت عملية خراطة لعينة جديدة باستخدام البارامترات الناتجة عن الخوارزمية وقياس

خشونة سطح لهذه العينة، وكانت النتيجة $R_a = 2.743 \mu m$ وهي قريبة على أفضل خشونة سطح من

العينات التجريبية (الجدول 5.5)، وبزمن تشغيل للعينة: 8 ثواني

2. إيجاد بارامترات القطع التي تعطي أقل خشونة سطح بتوسيع المجال المُحدَّد للقيمة.

استُخدمت مكتبة Pygad لتنفيذ الخوارزمية الجينية والكود البرمجي لتنفيذ الخوارزمية (الملحق رقم 8).

في هذه الحالة قُيِّمت الخوارزمية لإيجاد الحل الأمثل بتوسيع المجال المُحدَّد للقيمة (أي اختبار الخوارزمية على قيم لم تتدرب عليها والتي بدورها من الممكن أن تعطي نتائج أفضل من المجال المُحدَّد للقيمة). ومن خلال الأشكال (8.5)، (9.5)، (10.5) لوحظ أن معدل التغذية فقط تكون علاقته خطية، أي يمكن توسيع المجال لمعدل التغذية في حين سرعة الدوران وعمق القطع لم يتم تغيير مجالهما، ومن ثم حُدِّد المجال لكل بارامتر:

$$1274 \leq (N) \text{ سرعة الدوران} \leq 3822$$


$$0.05 \leq (F) \text{ معدل التغذية} \leq 0.25$$

$$0.6 \leq (d) \text{ عمق القطع} \leq 1$$

البارامترات التي أُدخلت للخوارزمية هي الحالة رقم 1 نفسها إذ: لوحظ أن عدد الأجيال الأفضل هو 100,000 إذ بعد زيادة هذا العدد لم يُلاحظ أي تحسُّن، في حين عدد الحلول في الجيل الواحد هو 500، وبزيادة هذه القيمة عن 500 لم يُلاحظ أي زيادة في دقة النموذج، وعملية الاختيار وجدت أن الاختيار عن طريق عجلة الروليت هو الأمثل في حين أنه في عملية التزاوج اختير التزاوج في نقطة واحدة والطفرة حُدِّدت لتكون بشكل عشوائي (أي تغيير بسيط في الحلول) والتي بدورها من الممكن أن تُعطي حلاً أفضل.

وآلية عمل الخوارزمية بالحالة رقم 1 نفسها في الجيل الأول تم توليد 500 حل بشكل عشوائي. ثم قُيِّمت هذه الحلول بحسب دالة اللياقة واختير أفضل هذه الحلول باستخدام عجلة الروليت، والحلول التي اختيرت تتزاوج في نقطة واحدة، وعُدِّلَت الحلول بشكل عشوائي لإجراء الطفرة. ثم انتقلت هذه الحلول للجيل الثاني وبإعادة الخطوات نفسها حتى الوصول إلى الجيل 100,000. في هذه الحالة حُدِّدت قيمة الخشونة المثلى الواجب على الخوارزمية الوصول إليها هي: 0.0000000000000001 أي للوصول إلى أنعم سطح، والشكل (27.5)

يبين العلاقة بين عدد الأجيال وكفاءة النموذج وقد لوحظ أن كفاءة النموذج هي $\approx 1000,000$



الشكل (27.5): العلاقة بين عدد الأجيال وكفاءة النموذج

البارامترات الناتجة عن الخوارزمية هي:

سرعة الدوران (N): 2377 r.p.m

معدل التغذية (F): 0.106 mm/rev

عمق القطع (d): 0.7 mm


ولتقييم هذه البارامترات أُجريت عملية خراطة لعينة جديدة باستخدام البارامترات الناتجة عن الخوارزمية وقياس

خشونة سطح لهذه العينة وكانت النتيجة $R_a = 0.944 \mu\text{m}$

وبزمن تشغيل للعينة: 7 ثواني

3. إيجاد بارامترات القطع التي تعطي أقل خشونة سطح بتوسيع المجال المُحدَّد للقيمة:

أُجريت عملية تقييم للخوارزمية بتوسيع المجال المُحدَّد للقيمة أي بالحالة رقم 2 نفسها ولكن لبيان إمكانية توليد حلول أفضل من الحالة رقم 2. الشكل (28.5) يبين العلاقة بين عدد الأجيال وكفاءة النموذج وقد لوحظ أن كفاءة النموذج هي $\approx 1000,000$ والكود البرمجي لتنفيذ الخوارزمية (الملحق رقم 8).



الشكل (28.5): العلاقة بين عدد الأجيال وكفاءة النموذج

لُوحظ أن البارامترات المُثلى الناتجة عن الخوارزمية هي:

3604	r.p.m	(N): سرعة الدوران
0.106	mm/rev	(F): معدل التغذية
0.7	mm	(d): عمق القطع

ولتقييم هذه البارامترات أُجريت عملية خراطة لعينة جديدة باستخدام البارامترات الناتجة عن الخوارزمية وقياس

خشونة سطح لهذه العينة وكانت النتيجة $R_a = 0.969 \mu m$

وبزمن تشغيل للعينة: 4 ثواني

ومن ثم تمكّنت الخوارزمية الجينية من الوصول للبارامترات المُثلى والتي تعطي أنعم سطح ضمن المجال وخارجة المُحدّد من قبل الشركة المصنعة للّقمة، وخشونة السطح وزمن التشغيل خارج المجال المحدد للّقمة أفضل من المجال ضمن حدود اللّقة كما هو مبين بالجدول رقم (7.5) إذ يمكن استخدام البارامترات الآتية في أثناء التشغيل:

(1) سرعة الدوران: 2377 r.p.m ومعدل التغذية: 0.106 mm/rev وعمق القطع: 0.7 mm والتي

أعطت خشونة سطح: $R_a = 0.944 \mu m$ وزمن التشغيل: 7 ثواني، إذا كانت خشونة السطح أهم من زمن التشغيل.

(2) سرعة الدوران: 3604 r.p.m ومعدل التغذية: 0.106 mm/rev وعمق القطع: 0.7 mm والتي

أعطت خشونة سطح: $R_a = 0.969 \mu m$ وزمن التشغيل: 4 ثواني، إذا كان زمن التشغيل أهم من خشونة السطح.

الجدول (7.5): البارامترات المثلى لتحسين نعومة السطح

البارامترات المثلى الناتجة عن الخوارزمية الجينية	ضمن المجال المحدد للقيمة	خارج المجال المحدد للقيمة	خارج المجال المحدد للقيمة
سرعة الدوران r.p.m	1274	2377	3604
معدل التغذية mm/rev	0.18	0.106	0.106
عمق القطع mm	0.9	0.7	0.7
خشونة السطح μm	2.743	0.944	0.969
زمن التشغيل ثانية	8	7	4

الفصل السادس: النتائج والمناقشة

في هذا الفصل عُرضت النتائج المستخلصة من البحث ومناقشة هذه النتائج

1.6. النتائج والمناقشة

من خلال إجراء هذا البحث استُخلصت النتائج الآتية:

1. من الجدول (5.5) لوحظ وجود تأثير لسرعة الدوران في خشونة السطح ولمعرفة هذا التأثير تُبنت البارامترات الأخرى (معدل التغذية، عمق القطع) وبتغيير هذا البارامتر إذ لوحظ في بعض الحالات بزيادة سرعة الدوران تزداد خشونة السطح وفي بعض الحالات بزيادة سرعة الدوران تتخفض خشونة السطح كما هو موضح في الشكل (8.5) وبالتالي استنتج أن العلاقة بين سرعة الدوران وخشونة السطح هي علاقة متغيرة وهذا يتفق مع [2] ولكن لوحظ من الجدول (5.5) أن تأثير سرعة الدوران في خشونة السطح تأثير ضعيف مقارنة مع معدل التغذية وبالتالي في حالات التشغيل التي لا تتطلب دقة عالية يمكن إهمال هذا البارامتر كون تأثيره ضعيف في خشونة السطح ولكن هذا يختلف مع [8] إذ استنتج الباحث أن لسرعة الدوران تأثير كبير في نعومة السطح وبزيادة سرعة الدوران تم تحسين نعومة السطح وبالتالي يمكن استنتاج أنه لا يمكن تعميم النتيجة التي حُصل عليها لجميع المعادن إذ يجب دراسة تأثير بارامترات القطع في خشونة السطح لكل معدن.

2. من الجدول (5.5) لوحظ وجود تأثير لعمق القطع في خشونة السطح ولمعرفة هذا التأثير تُبنت البارامترات الأخرى (سرعة الدوران، معدل التغذية) وبتغيير هذا البارامتر إذ لوحظ بزيادة عمق القطع تزداد خشونة السطح ثم تعود للانخفاض كما هو موضح بالشكل (9.5) وبالتالي استنتج أن العلاقة بين عمق القطع وخشونة السطح هي علاقة متغيرة وهذا يتفق مع [2] ولكن لوحظ من الجدول (5.5) أن تأثير عمق القطع في خشونة السطح تأثير ضعيف مقارنة مع معدل التغذية وبالتالي في حالات التشغيل التي لا تتطلب دقة عالية يمكن إهمال هذا البارامتر كون تأثيره ضعيف في خشونة السطح.

3. من الجدول (5.5) لوحظ وجود تأثير لمعدل التغذية في خشونة السطح ولمعرفة هذا التأثير تُبنت البارامترات الأخرى (سرعة الدوران، عمق القطع) وبتغيير هذا البارامتر إذ لوحظ بزيادة معدل التغذية في جميع الحالات تزداد خشونة السطح كما هو مبين في الشكل (10.5) وبالتالي استنتج أن العلاقة بين معدل التغذية وخشونة السطح هي علاقة خطية وهذا يتفق مع [2,8,9,10] وأيضاً من الجدول (5.5) لوحظ أن تأثير معدل التغذية في خشونة السطح تأثيره كبير في خشونة السطح على عكس تأثير كلاً من سرعة الدوران وعمق القطع وبالتالي في جميع عمليات التشغيل يجب أخذه في الاعتبار كون تأثيره كبير في خشونة السطح وخصوصاً في الصناعات الدقيقة التي تتطلب خشونة سطح دقيقة جداً.

4. من خلال النتائج السابقة لوحظ أن لبارامترات القطع تأثير في خشونة السطح ولكن لا يوجد علاقة تربط بين هذه البارامترات لذلك استُخدمت خوارزميات جديدة لم يتم العمل بها كثيراً في شتى المجالات والتي استُخدمت في هذه الدراسة منها الانحدار الخطي للتنبؤ بخشونة السطح قبل إجراء عمليات التشغيل ولُوحظ أن هذا النظام لم يتطلب الكثير من البارامترات لبرمجته فقط تطلب إعطاء هذا النظام عينات التدريب مع قيمة الخشونة الموافقة لكل منها وأيضاً عملية التدريب لم تستغرق الكثير من الوقت وقد بلغت نسبة الخطأ في هذا النظام $MSE = 0.00856$ وبالنظر إلى الدراسات السابقة وُجد عدد قليل جداً من الدراسات التي استخدمت الانحدار الخطي للتنبؤ بخشونة السطح منها الدراسة [28] إذ بلغت نسبة الخطأ باستخدام الانحدار الخطي $MSE = 0.0184$ وبنفس المعدن المستخدم في هذه الدراسة AISI 1040 ولكن لأداة قطع مختلفة والتي من الممكن أن يكون لها تأثير في دقة النظام وبالتالي يمكن الاعتماد على هذا النظام في عملية التنبؤ بخشونة السطح في الصناعات المختلفة التي لا تتطلب دقة عالية جداً ومن الممكن أن يكون عدم وجود بارامترات عديدة في أثناء برمجة الانحدار هو أحد الأسباب التي تؤثر على دقة النظام كونه في بعض الخوارزميات مثلاً (الشبكات العصبونية) لوحظ أنه بزيادة عدد البارامترات زادت دقة النظام.

5. استخدمت خوارزمية شجرة القرار في عملية التنبؤ بخشونة السطح وهي أيضاً من الخوارزميات القليلة التي تستخدم في المجالات المختلفة ولُوحظ أيضاً أن هذا النظام لم يتطلب الكثير من البارامترات لبرمجته فقط

تطلب إعطاء هذا النظام عينات التدريب مع قيمة الخشونة الموافقة لكل منها وأيضاً عملية التدريب لم تستغرق الكثير من الوقت ولكن استغرقت عملية التدريب وقت أطول من الانحدار الخطي ويمكن تفسير ذلك في محاولتها الوصول إلى دقة أفضل من الانحدار الخطي وقد بلغت نسبة الخطأ في هذا النظام $MSE = 0.00574$ وهي أفضل من الانحدار الخطي ولكن عند البحث في الدراسات السابقة لم يتم ملاحظة دراسة سابقة استخدمت فيها شجرة القرار للتنبؤ بخشونة السطح وبالتالي يمكن الاعتماد على هذا النظام في عملية التنبؤ بخشونة السطح في الصناعات التي لا تتطلب دقة عالية جداً ومن الممكن أن يكون عدم وجود تدخل من قبل المستخدم هو أحد الأسباب التي أدت إلى ضعف دقة التنبؤ باستخدامها فكما هو مبين بالشكل (14.5) لوحظ أن عملية التقسيم والتكرار واختيار الشرط في كل عقدة للوصول إلى أقل نسبة للخطأ تم بشكل تلقائي من قبل الخوارزمية.

6. استُخدمت خوارزمية الغابة العشوائية في عملية التنبؤ بخشونة السطح وهي من الخوارزميات التي لم يتم ملاحظتها في المجالات المختلفة وخصوصاً في الميكانيك ولوحظ أن هذا النظام تطلب تحديد بارامتر وهو عدد الأشجار في الغابة العشوائية إذ حُدِد عدد الأشجار الأمثل هو 10 أشجار وعملية التدريب استغرقت وقت أطول من شجرة القرار وأيضاً كلما زاد عدد الأشجار لوحظ زيادة المعالجة وبالتالي وقت أطول للمعالجة ومن الممكن أن يكون هذا هو السبب في التوصل إلى دقة أفضل من الأنظمة السابقة إذ بلغت نسبة الخطأ في هذا النظام $MSE = 0.00472$ وأيضاً في [29] فقد توصل الباحث إلى أن الغابة العشوائية أعطت دقة أفضل من الانحدار الخطي ولكن المعدن المستخدم في الدراسة هو AISI 4340 وبالتالي يمكن الاعتماد على هذا النظام للتنبؤ بخشونة السطح في الصناعات إذا كانت دقة هذا النظام مقبولة وكونها أعطت دقة أفضل من الانحدار الخطي وشجرة القرار ولكن من سلبيات هذا النظام هو في حاجته إلى تحديد عدد الأشجار الأمثل والتي تعتمد على مبدأ التجريب والخطأ.

7. استُخدمت الشبكات العصبونية في عملية التنبؤ بخشونة السطح وهي من أكثر الخوارزميات المستخدمة في شتى المجالات وخصوصاً في عملية التنبؤ بخشونة السطح ولوحظ أن هذا النظام استغرق الكثير من

الوقت والدراسة لمعرفة استخدام هذا النظام على عكس الخوارزميات السابقة التي لم تتطلب الكثير من الوقت لمعرفة كيفية برمجتها وأيضاً يوجد العديد من البارامترات التي يجب ضبطها أثناء برمجة الشبكة العصبونية: عدد العصبونات ووظيفتها هي زيادة المعالجة للوصول لأفضل دقة إذ حُدد عدد العصبونات الأمثل هو 300 عصبون وهو رقم كبير جداً ولكن لمحاولة الوصول إلى خوارزمية تعطي أفضل دقة للتنبؤ بخشونة السطح في الصناعات الدقيقة جداً وأيضاً تابع التنشيط الأمثل هو تابع relu حُدد أيضاً بالتجربة وتابع الخسارة حُدد MSE بينما تابع التحسين استخدم تابع SGD وأيضاً حُدد بالتجريب للوصول لأفضل تابع وأيضاً معدل التعلم حُدد بقيمة 0.0001 وبالتالي تطلب هذا النظام عدد مرات معالجة كبير جداً $epochs = 600,000$ والتي بدورها استغرقت الكثير من الوقت بينما في [2] فقد استخدم الباحث شبكة عصبونية مؤلفة من 18 عصبون فقط للتنبؤ بخشونة السطح لمعدن CK 60 ونسبة خطأ $MSE = 0.0637$ ومن الممكن أن نسبة الخطأ العالية التي توصل لها الباحث تعود إلى عدد العصبونات القليل بينما في [30] فقد توصل الباحث إلى نسبة خطأ $MSE = 0.00067$ لمعدن C38 وهي أفضل من القيمة التي توصلت لها هذه الدراسة وبالتالي يمكن الاعتماد على هذا النظام للتنبؤ بخشونة السطح في الصناعات المختلفة وخصوصاً الدقيقة منها ولكن من سلبيات هذا النظام هو أنه استغرق الكثير من الوقت من الممكن أن يكون لمحاولة الوصول لأفضل دقة وأيضاً بسبب البارامترات العديدة التي يجب ضبطها أثناء البرمجة.

8. استخدمت الشبكات العصبونية المُدرَّبة بواسطة الخوارزميات الجينية للتنبؤ بخشونة السطح إذ من أهم تطبيقات الخوارزميات الجينية هو عملية تدريب الشبكات العصبونية واختيار الأوزان المثلى ولُوحظ أن هذا النظام تطلب عدد قليل من البارامترات على عكس الشبكات العصبونية التقليدية فمثلاً الشبكة العصبونية المستخدمة تحتوي على 5 عصبونات فقط بينما في الشبكة العصبونية السابقة تطلبت 300 عصبون وتابع التنشيط المستخدم هو تابع relu وتابع الخسارة MSE بينما تابع التحسين لم يتم تحديده وهو ماحسن الزمن المستغرق في عملية التدريب للوصول إلى الأوزان المثلى بينما الخوارزمية الجينية

تطلبت بعض البارامترات التي يجب تحديدها مثل: عدد الأجيال حُدِد عدد الأجيال الأمثل هو 2000 جيل بالتجريب وعدد الحلول الأمثل (شبكة عصبونية) في الجيل الواحد هو 40 حل بينما طريقة الاختيار حُدِدَت ليكون الاختيار عن طريق عجلة الروليت بينما طريقة التزاوج حُدِدَت لتكون التزاوج في نقطة واحدة وعملية التدريب لم تستغرق كثيراً من الوقت مقارنة مع النظام السابق وقد بلغت نسبة الخطأ في هذا النظام $MSE = 0.000446$ بينما في [28] فقد استخدم الباحث شبكة عصبونية للتنبؤ بخشونة السطح ولنفس المعدن المستخدم في الدراسة الحالية وقد بلغت نسبة الخطأ $MSE = 0.00152$ والدقة التي توصلت لها هذه الدراسة أفضل دقة من جميع الأنظمة السابقة وبالتالي هذا النظام يمكن اعتماده للتنبؤ بخشونة السطح في الصناعات المختلفة وخصوصاً في الصناعات الدقيقة ويمكن تفسير الدقة العالية لهذا النظام هو في كونه يتم توليد العديد من الشبكات العصبونية في كل جيل وبالتالي يتم الوصول إلى الأوزان المثلى بوقت قليل على عكس الشبكة العصبونية التقليدية التي تعتمد على أوزان يتم تحديدها بشكل عشوائي وبالتالي مع عدد مرات المعالجة تتحسن هذه الأوزان وهكذا حتى الوصول إلى الأوزان المثلى ولكن هذا النظام تطلب وقت أطول من الانحدار الخطي، شجرة القرار، الغابة العشوائية.

9. في بعض الحالات يُطلب الحصول على أنعم سطح لذلك استُخدمت الخوارزميات الجينية للوصول إلى البارامترات المثلى والتي تعطي أنعم سطح والخوارزميات الجينية تتطلب بعض البارامترات: المجال المُحدّد لبارامترات القطع إذ لوحظ في جميع الدراسات السابقة يُحدّد المجال لبارامترات القطع كما هو مُحدّد من قبل الشركة المُصنعة للقيمة المستخدمة كما في [31] إذ قام الباحث بالتوصل للبارامترات المثلى (سرعة الدوران، معدل التغذية، زاوية الجرف) والتي تعطي أقل خشونة للسطح في عملية التفريز بينما في هذه الدراسة لوحظ أن العلاقة بين معدل التغذية وخشونة السطح هي علاقة خطية كما هو مبين في الشكل (10.5) لذلك تم توسيع المجال لمعدل التغذية بحيث تبدأ الخوارزمية بتوليد الحلول بدءاً من 0.05 بدلاً من 0.18 لمحاولة تحسين خشونة السطح وأيضاً لبيان إمكانية الخوارزمية الوصول للحل الأمثل حتى بالنسبة لقيم لم تكن مُدربة عليها وحُدِد عدد الأجيال الأمثل هو 100,000 وعدد الحلول الأمثل في الجيل الواحد هو

500 حل وعملية الإختيار هو الإختيار عن طريق عجلة الروليت بينما عملية التزاوج هي التزاوج في

نقطة واحدة وبالتالي البارامترات الناتجة عن الخوارزمية الجينية هي:

(a) سرعة الدوران: 2377 r.p.m ومعدل التغذية: 0.106 mm/rev وعمق القطع: 0.7 mm والتي

أعطت خشونة سطح: $R_a = 0.944 \mu m$ وهي أفضل من العينات التجريبية وبزمن التشغيل: 7

ثواني، إذ كانت خشونة السطح أهم من زمن التشغيل.

(b) سرعة الدوران: 3604 r.p.m ومعدل التغذية: 0.106 mm/rev وعمق القطع: 0.7 mm والتي

أعطت خشونة سطح: $R_a = 0.969 \mu m$ وهي أفضل من العينات التجريبية وبزمن التشغيل: 4

ثواني، إذ كان زمن التشغيل أهم من خشونة السطح.

وللوصول لهذه البارامترات لوحظ أن الخوارزمية تعمل بسرعة عالية جداً إذ أن الجيل الواحد استغرق أقل من ثانية واحدة ومن سلبيات هذه الخوارزمية هو حاجتها إلى دراسة عميقة لفهم آلية عملها وأيضاً حاجتها إلى ضبط العديد من البارامترات ولوحظ أن خشونة السطح الناتجة من الخوارزمية أفضل من العينات التجريبية المبينة في الجدول (5.5) التي تم تشغيلها تبعاً للمجال المحدد للقيمة المستخدمة ولكن أفضل خشونة حصل عليها هي تقريباً $0.9 \mu m$ وبالتالي لم تتمكن الخوارزمية من الحصول أقل من هذه القيمة كونه في بعض الحالات يُطلب قيمة خشونة سطح أقل من هذه القيمة.

10. تتجلى أهمية هذه الدراسة في كونه تمت مقارنة 5 خوارزميات للتنبؤ بخشونة السطح بينما في جميع

الدراسات السابقة [2,8,9,10,28,29,30,31] يتم مقارنة خوارزميتين على الأكثر وتم التعرف على

خوارزميات لم يتم استخدامها كثيراً في الميكانيك عامة وفي مجال التنبؤ بخشونة السطح خاصة وتم

التوصل إلى نظام هجين (الشبكات العصبونية المدربة بواسطة الخوارزميات الجينية) والذي أعطى متوسط

الخطأ التربيعي $MSE = 0.000446$ وبالمقارنة مع الدراسات السابقة التي استخدمت هذا المعدن أو

لمعادن مختلفة لم يتم التوصل لهذه الدقة وأيضاً تم التوصل إلى البارامترات المثلى والتي أعطت نعومة

سطح أفضل من العينات التجريبية وتتجلى قيود هذه الدراسة في كونها محدّدة لمعدن واحد فقط

AISI 1040 أي جميع الأنظمة السابقة هي خاصة فقط لهذا المعدن ولكن نظراً لضيق الوقت لم تتمكن هذه الدراسة من استخدام معادن أخرى أو محاولة تقييم هذه الأنظمة على معادن مختلفة لبيان إمكانية استخدامها أم لا.

الفصل السابع: التوصيات والآفاق المستقبلية

1.7. التوصيات

اعتماداً على النتائج السابقة قُدمت التوصيات الآتية:

1. يُوصى بتجنب استخدام الأساليب التقليدية في تحديد بارامترات القطع مثل: الاعتماد على خبرة العامل إذ يؤدي ذلك إلى خشونة سطح مختلفة عن المطلوبة، ويمكن أن تؤدي هذه الخشونة إلى زيادة الاحتكاك بين الأجزاء المتحركة، زيادة معدل التآكل، تقليل عمر القطعة، أو حتى التخلص من القطعة المشغلة.
 2. استخدام النظام الذكي المُطوّر (الشبكات العصبونية المدربة بوساطة الخوارزمية الجينية) للتعويض بخشونة السطح في الصناعات المختلفة وخصوصاً في الصناعات الدقيقة التي تتطلب خشونة سطح معينة مثل: صناعة الطائرات (أجزاء ميكانيكية، هياكل داخلية)، صناعة السيارات (عمود الكرنك)، الأجزاء الميكانيكية وقطع المعدات الداخلية للمحركات والمولدات، وغيرها..
 3. تنظيم دورات تدريبية لتأهيل العاملين على استخدام النظام الذكي المُطوّر (الشبكات العصبونية المدربة بوساطة الخوارزمية الجينية).
 4. استخدام البارامترات المثلى عندما يُطلب الحصول على أفضل نعومة سطح في الصناعات المختلفة وخصوصاً في: الأجزاء الهيدروليكية (صمامات، مكابس،..)، الأدوات الطبية، المحامل، محاور الآلات، الطيران والفضاء وغيرها.. وهي:
- (a) سرعة الدوران: 2377 r.p.m ومعدل التغذية: 0.106 mm/rev وعمق القطع: 0.7 mm والتي أعطت خشونة سطح: $R_a = 0.944 \mu m$ وزمن التشغيل: 7 ثواني، إذ كانت خشونة السطح أهم من زمن التشغيل.

(b) سرعة الدوران: 3604 r.p.m ومعدل التغذية: 0.106 mm/rev وعمق القطع: 0.7 mm والتي أعطت خشونة سطح: $R_a = 0.969 \mu m$ وزمن التشغيل: 4 ثواني، إذ كان زمن التشغيل أهم من خشونة السطح.

2.7. مقترحات لأعمال بحثية مستقبلية

1. مقارنة النظام الذكي المطور (الشبكات العصبونية المدربة بواسطة الخوارزمية الجينية) للتعقب بخشونة السطح مع خوارزميات الذكاء الصناعي الأخرى مثل:

(Ridge Regression, Lasso Regression, Support Vector Machines)

2. مقارنة البارامترات المثلى التي توصلت إليها الخوارزمية الجينية مع خوارزميات الحل الأمثل الأخرى مثل:

(Particle Swarm Optimization (PSO), Ant Colony Optimization Algorithm)

3. استخدام النظام الذكي المطور (الشبكات العصبونية المدربة بواسطة الخوارزمية الجينية) في استخدامات أخرى مثل: (الكشف عن الأخطاء والأعطال، التحكم في العمليات، التصميم والتحسين).

4. استطاعت الخوارزميات الجينية الوصول إلى الحل الأمثل حتى بالنسبة للبيانات التي لم تتدرب عليها ومن ثم هذا يساعد في تخفيف كثير من الوقت والتكلفة إذ يمكن تشغيل قسم من العينات لبناء النموذج ثم توسيع المجال للخوارزمية والتي أثبتت إمكانياتها بالوصول إلى الحل الأمثل.

5. إجراء دراسة مماثلة على معادن أخرى مثل الألمنيوم والبرونز، والتي تتطلب تحقيق خشونة سطح محددة.

الأعمال المرافقة للبحث

1. نُشر بحث بعنوان: "تقييم أداء خوارزميات الذكاء الصنعي للتنبؤ بخشونة السطح في عمليات الخراطة"

(2023) - مجلة جامعة دمشق.

المراجع References

1. الموسوي، علي. (2013). عملية تصنيع المعادن. بابل: العراق. ص: 288.
2. كركرلي، جمانة. (2014). استخدام الذكاء الصناعي لنمذجة العلاقة بين خشونة السطح ومتغيرات القطع بالخرائطة. تصميم ميكانيكي. كلية الهندسة الميكانيكية والكهربائية. جامعة دمشق. دمشق: سورية. ص: 160.
3. حداد، غسان. (2008). طرائق التصنيع (1). دمشق: سورية. ص: 583.
4. المؤسسة العامة للتدريب التقني والمهني. تشغيل آلات الخراطة. الرياض: المملكة العربية السعودية. ص: 179.
5. شرف، خالد. (2014). علم القياس والقياسات الميكانيكية. دمشق: سورية. ص: 497.
6. Whitehouse, D. J. (2010). Handbook of surface and nanometrology. CRC press.
7. Pont, S. C., & Koenderink, J. J. (2008). Shape, surface roughness and human perception. In Handbook of texture analysis (pp. 197-222).
8. Erçetin, A., & Usca, Ü. A. (2016). An experimental investigation of effect of turning AISI 1040 steel at low cutting speed on tool wear and surface roughness.
9. Prakash, D. B., Krishnaiah, D. G., & Shankar, N. V. S. (2016). Optimization of process parameters using Taguchi techniques when turning AISI 1040 steel with coated tools. International Journal of Mechanical Engineering and Technology (IJMET).
10. Rodrigues, L. L. R., Kantharaj, A. N., Kantharaj, B., Freitas, W. R. C., & Murthy, B. R. N. (2012). Effect of cutting parameters on surface roughness and cutting force in turning mild steel. Research Journal of Recent Sciences.
11. Petre, E. G. (2009). A decision tree for weather prediction. Universitatea Petrol-Gaze din Ploiesti, 61(1), 77-82.
12. Nasiri, S., Khosravani, M. R., & Weinberg, K. (2017). Fracture mechanics and mechanical fault detection by artificial intelligence methods: A review. Engineering Failure Analysis, 81, 270-293.
13. Cabrera, J. A., Simon, A., & Prado, M. (2002). Optimal synthesis of mechanisms with genetic algorithms. Mechanism and machine theory, 37(10), 1165-1177.
14. Jakiela, M. J., Chapman, C., Duda, J., Adewuya, A., & Saitou, K. (2000). Continuum structural topology design with genetic algorithms. Computer Methods in Applied Mechanics and Engineering, 186(2-4), 339-356.
15. Winston, P. H. (1984). Artificial intelligence. Addison-Wesley Longman Publishing Co., Inc..
16. Moolayil, J., Moolayil, J., & John, S. (2019). Learn Keras for deep neural networks (pp. 33-35). Birmingham: Apress.

17. Suzuki, K. (Ed.). (2013). **Artificial neural networks: Architectures and applications**. BoD–Books on Demand.
18. Vasilev, I., Slater, D., Spacagna, G., Roelants, P., & Zocca, V. (2019). **Python Deep Learning: Exploring deep learning techniques and neural network architectures with Pytorch, Keras, and TensorFlow**. Packt Publishing Ltd.
19. Carr, J. (2014). **An introduction to genetic algorithms**. Senior Project, 1(40), 7.
20. Mirjalili, S., & Mirjalili, S. (2019). **Genetic algorithm. Evolutionary Algorithms and Neural Networks**: Theory and Applications, 43-55.
21. Papazoglou, G., & Biskas, P. (2023). **Review and Comparison of Genetic Algorithm and Particle Swarm Optimization in the Optimal Power Flow Problem**. Energies, 16(3), 1152.
22. Baştanlar, Y., & Özuysal, M. (2014). **Introduction to machine learning. miRNomics: MicroRNA biology and computational analysis**, 105-128.
23. Bressan, M., Damay, G., & Sozio, M. (2022). **Fully-Dynamic Decision Trees**. arXiv preprint arXiv:2212.00778.
24. Gross, J., & Groß, J. (2003). **Linear regression** (Vol. 175). Springer Science & Business Media.
25. Biau, G., & Scornet, E. (2016). **A random forest guided tour**. Test, 25, 197-227.
26. Rigatti, S. J. (2017). **Random forest**. Journal of Insurance Medicine, 47(1), 31-39.
27. **Walter General Catalog**.(2018).North America.
28. Asiltürk, I., & Çunkaş, M. (2011). **Modeling and prediction of surface roughness in turning operations using artificial neural network and multiple regression method**. Expert systems with applications, 38(5), 5826-5832.
29. Agrawal, A., Goel, S., Rashid, W. B., & Price, M. (2015). **Prediction of surface roughness during hard turning of AISI 4340 steel (69 HRC)**. Applied Soft Computing, 30, 279-286.
30. Boukezzi, F., Noureddine, R., Benamar, A., & Noureddine, F. (2017). **Modelling, prediction and analysis of surface roughness in turning process with carbide tool when cutting steel C38 using artificial neural network**. International Journal of Industrial and Systems Engineering, 26(4), 567-583.
31. Zain, A. M., Haron, H., & Sharif, S. (2010). **Application of GA to optimize cutting conditions for minimizing surface roughness in end milling machining process**. Expert Systems with Applications, 37(6), 4650-4659.

الملاحق

الملحق رقم (1)

G-codes للعينه رقم 2+1

%

O1000

G53 G00 X0 Z0

T0707

G99 G97 S1274 M3

G0 X+51.1072 Z66.6971 M8

G0 X+53.291

Z67.2321

X+28.4

G1 X+23.4 F.075

Z62.2321 F.18

Z42.2321

G0 X+53.291

Z66.6971

X+51.1072

X+51.8808 Z42.2408

X+52.0366

Z47.2321

X+28.8

G1 X+23.8 F.075

Z42.2321 F.18

Z22.6321

X+24.2

G0 X+52.0366

Z42.2408

X+51.8808

M5 M9

M30

%

الملحق رقم (2)

الكود البرمجي للانحدار الخطي

```
#import libraries
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, mean_absolute_error
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import joblib

# read the samples
file=pd.read_csv('C:\\Users\\USER\\Desktop\\samples.csv')
x=np.asarray(file[['speed', 'feed', 'depth']])
y=np.asarray(file[['rough']])

#split the data
xtrain,xtest,ytrain,ytest=train_test_split(x,y,train_size=0.8,random_state=
10)
xtrain,xval,ytrain,yval=train_test_split(xtrain,ytrain,test_size=0.1,random
_state=10)

# create the model
model=LinearRegression()
model.fit(xtrain,ytrain)

#predict
predicted=model.predict(xtest)

#Evaluation the model
MSE=print(mean_squared_error(ytest,predicted))

# plot
plt.plot(ytest,'ob',label='Actual',markersize=9)
plt.plot(predicted,'+r',label='Predicted',markersize=16)
plt.legend(shadow=True,loc='best',fontsize=15)
plt.grid()
plt.xlabel('Samples',fontsize=16)
plt.ylabel('Roughness',fontsize=16)
plt.title('Actual VS Predicted with LinearRegression',fontsize=16)
plt.show()

# Save the model
filename='LinearRegression'
joblib.dump(model,filename)
```

الملحق رقم (3)

الكود البرمجي لشجرة القرار

```
# import libraries
import joblib
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.tree import DecisionTreeRegressor, plot_tree
from sklearn.metrics import mean_squared_error, mean_absolute_error
import matplotlib.pyplot as plt

# read the samples
file=pd.read_csv('C:\\\\Users\\\\USER\\\\Desktop\\samples.csv')
x=np.asarray(file[['speed', 'feed', 'depth']])
y=np.asarray(file[['rough']])

#split the data
xtrain,xtest,ytrain,ytest=train_test_split(x,y,train_size=0.8,random_state=
10)
xtrain,xval,ytrain,yval=train_test_split(xtrain,ytrain,test_size=0.1,random
_state=10)

#create the model
model=DecisionTreeRegressor()
model.fit(xtrain,ytrain)

#predict
predicted=model.predict(xtest)

#Evaluation the model
print(mean_squared_error(ytest,predicted))

# plot
plt.plot(ytest,'ob',label='Actual',markersize=9)
plt.plot(predicted,'+r',label='Predicted',markersize=16)
plt.legend(shadow=True,loc='best',fontsize=15)
plt.grid()
plt.xlabel('Samples',fontsize=16)
plt.ylabel('Roughness',fontsize=16)
plt.title('Actual VS Predicted with DecisionTree',fontsize=16)
plt.figure(figsize=(20,10))
plot_tree(model,filled=True)
plt.show()

# Save the model
filename='DecisionTree'
joblib.dump(model,filename)
```

الملحق رقم (4)

الكود البرمجي للغابة العشوائية

```
# import libraries
import joblib
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error, mean_absolute_error
import matplotlib.pyplot as plt
from sklearn.tree import DecisionTreeRegressor, plot_tree
import warnings
warnings.filterwarnings('ignore')

# read the samples
file=pd.read_csv('C:\\Users\\USER\\Desktop\\samples.csv')
x=np.asarray(file[['speed', 'feed', 'depth']])
y=np.asarray(file[['rough']])

#split the data
xtrain,xtest,ytrain,ytest=train_test_split(x,y,train_size=0.8,random_state=
10)
xtrain,xval,ytrain,yval=train_test_split(xtrain,ytrain,test_size=0.1,random
_state=10)

#create the model
model=RandomForestRegressor(n_estimators=10)
model.fit(xtrain,ytrain)

# Predict
predicted=model.predict(xtest)
#Evaluation the model
print(mean_squared_error(ytest,predicted))

# plot
for i in range(len(model.estimators_)):
    plot_tree(model.estimators_[i])
    plt.show()
plt.plot(ytest,'ob',label='Actual',markersize=9)
plt.plot(predicted,'+r',label='Predicted',markersize=16)
plt.legend(shadow=True,loc='best',fontsize=15)
plt.grid()
plt.xlabel('Samples',fontsize=16)
plt.ylabel('Roughness',fontsize=16)
plt.title('Actual VS Predicted with RandomForest',fontsize=16)
plt.show()

# Save the model
filename='RandomForest'
joblib.dump(model,filename)
```

الملحق رقم (5)

الكود البرمجي للشبكة العصبونية

```
# import libraries
import numpy as np
import pandas as pd
from keras.callbacks import History
import matplotlib.pyplot as plt
from keras import layers
from keras import models
from sklearn.preprocessing import MinMaxScaler, StandardScaler
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, mean_absolute_error
from keras.optimizers import SGD
history=History()
scale=MinMaxScaler()

# read the samples
file=pd.read_csv('C:\\Users\\USER\\Desktop\\samples.csv')
x=np.asarray(file[['speed', 'feed', 'depth']])
y=np.asarray(file[['rough']])

# split the data
xtrain,xtest,ytrain,ytest=train_test_split(x,y,train_size=0.8,random_state=
1)
xtrain,xval,ytrain,yval=train_test_split(xtrain,ytrain,test_size=0.1,random
_state=1)
xtrain=scale.fit_transform(xtrain)
xval=scale.fit_transform(xval)
xtest=scale.fit_transform(xtest)

#create the model
model=models.Sequential()
model.add(layers.Dense(300,input_dim=3,activation='relu',kernel_initializer
='normal'))
model.add(layers.Dense(1))
model.compile(loss='MSE',optimizer=SGD(learning_rate=0.0001),metrics=['MSE'
])
model.fit(xtrain,ytrain,epochs=600000,verbose=2,batch_size=1,callbacks=[his
tory],validation_data=(xval,yval))

# Predict
predicted=model.predict(xtest)

# Evaluation the model
print(mean_squared_error(ytest,predicted))

# plot
plt.plot(history.history['loss'],'blue')
plt.plot(history.history['val_loss'],'--r')
plt.xlabel('Epochs')
plt.ylabel('Loss')
```

```
plt.legend(['Training', 'validation'], loc='best')
plt.show()
plt.plot(ytest, 'ob', label='Actual', markersize=9)
plt.plot(predicted, '+r', label='Predicted', markersize=16)
plt.legend(shadow=True, loc='best', fontsize=15)
plt.grid()
plt.xlabel('Samples', fontsize=16)
plt.ylabel('Roughness', fontsize=16)
plt.title('Actual VS Predicted with NeuralNetworks', fontsize=16)
plt.show()

# Save the model
model.save('D:\\NeuralNetwork.h5')
```

الملحق رقم (6)

الكود البرمجي للشبكة العصبونية المدربة بواسطة الخوارزمية الجينية

```
# import libraries
import pygad.kerasga
import numpy as np
import tensorflow
import pandas as pd
import pygad
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error

# read the samples
scale=MinMaxScaler()
file=pd.read_csv('C:\\Users\\USER\\Desktop\\samples.csv')
x=np.asarray(file[['speed', 'feed', 'depth']])
y=np.asarray(file[['rough']])

# split the data
xtrain,xtest,ytrain,ytest=train_test_split(x,y,train_size=0.8,random_state=
1)
xtrain,xval,ytrain,yval=train_test_split(xtrain,ytrain,test_size=0.1,random
_state=1)
xtrain=scale.fit_transform(xtrain)
xval=scale.fit_transform(xval)
xtest=scale.fit_transform(xtest)
# Data inputs
data_inputs = xtrain

# Data outputs
data_outputs = ytrain

#create the model
def fitness_func(solution, sol_idx):
    global data_inputs, data_outputs, keras_ga, model

    model_weights_matrix =
pygad.kerasga.model_weights_as_matrix(model=model,

weights_vector=solution)

    model.set_weights(weights=model_weights_matrix)

    predictions = model.predict(data_inputs)

    MSE = mean_squared_error(data_outputs, predictions)+ 0.00000001
    solution_fitness = 1.0 / MSE

    return solution_fitness

def callback_generation(ga_instance):
    print("Generation =
{generation}".format(generation=ga_instance.generations_completed))
    print("Fitness =
```

```

{fitness}").format(fitness=ga_instance.best_solution()[1]))

input_layer = tensorflow.keras.layers.Input(3)
dense_layer1 = tensorflow.keras.layers.Dense(5,
activation="relu")(input_layer)
output_layer = tensorflow.keras.layers.Dense(1,
activation="linear")(dense_layer1)

model = tensorflow.keras.Model(inputs=input_layer, outputs=output_layer)

weights_vector = pygad.kerasga.model_weights_as_vector(model=model)

keras_ga = pygad.kerasga.KerasGA(model=model,
                                num_solutions=40)

num_generations = 2000
num_parents_mating = 2
initial_population = keras_ga.population_weights

ga_instance = pygad.GA(num_generations=num_generations,
                       num_parents_mating=num_parents_mating,
                       initial_population=initial_population,
                       fitness_func=fitness_func,
                       on_generation=callback_generation)

ga_instance.run()

solution, solution_fitness, solution_idx = ga_instance.best_solution()
print("Fitness value of the best solution =
{solution_fitness}).format(solution_fitness=solution_fitness))
print("Index of the best solution :
{solution_idx}).format(solution_idx=solution_idx))

best_solution_weights = pygad.kerasga.model_weights_as_matrix(model=model,
weights_vector=solution)
model.set_weights(best_solution_weights)

# Predict
predictions_testing = model.predict(xtest)

# Evaluation the model
MSE_Testing=mean_squared_error(ytest,predictions_testing)
print('MSE_Testing',MSE_Testing)

# save the model
save=model.save('D:\\NNGA2.h5')
ga_instance.plot_fitness(title="PyGAD & Keras - Iteration vs. Fitness",
linewidth=4)

```

الملحق رقم (7)

الكود البرمجي للخوارزمية الجينية للحل الأمثل (الحالة 1)

```
import pygad
import numpy as np

desired_output = 0.0000000000000001

def fitness_func(solution, solution_idx):
    output = -3.545+0.000064*solution[0]+34.69*solution[1]-
0.598*solution[2]-
0.000421*solution[0]*solution[1]+0.000015*solution[0]*solution[2]+2.61*solu
tion[1]*solution[2]
    fitness = 1.0 / (np.abs(output - desired_output) + 0.000001)
    return fitness

num_generations = 100000
num_parents_mating = 2

sol_per_pop = 500
num_genes = 3

last_fitness = 0
def on_generation(ga_instance):
    global last_fitness
    print("Generation =
{generation}".format(generation=ga_instance.generations_completed))
    print("Fitness =
{fitness}".format(fitness=ga_instance.best_solution(pop_fitness=ga_instance.l
ast_generation_fitness)[1]))
    print("Change =
{change}".format(change=ga_instance.best_solution(pop_fitness=ga_instance.l
ast_generation_fitness)[1] - last_fitness))
    last_fitness =
ga_instance.best_solution(pop_fitness=ga_instance.last_generation_fitness)[
1]

ga_instance = pygad.GA(num_generations=num_generations,
                        num_parents_mating=num_parents_mating,
                        sol_per_pop=sol_per_pop,
                        num_genes=num_genes,
                        fitness_func=fitness_func,
                        on_generation=on_generation,
gene_space=[{'low':1274, 'high':3822}, {'low':0.18, 'high':0.25}, {'low':0.6, 'h
igh':1.0}])

ga_instance.run()

ga_instance.plot_fitness()

solution, solution_fitness, solution_idx =
ga_instance.best_solution(ga_instance.last_generation_fitness)
print("Parameters of the best solution :
{solution}".format(solution=solution))
print("Fitness value of the best solution =
{solution_fitness}".format(solution_fitness=solution_fitness))
```

```

print("Index of the best solution :
{solution_idx}".format(solution_idx=solution_idx))

prediction = -3.545+0.000064*solution[0]+34.69*solution[1]-
0.598*solution[2]-
0.000421*solution[0]*solution[1]+0.000015*solution[0]*solution[2]+2.61*solu
tion[1]*solution[2]
print("Predicted output based on the best solution :
{prediction}".format(prediction=prediction))

if ga_instance.best_solution_generation != -1:
    print("Best fitness value reached after {best_solution_generation}
generations.".format(best_solution_generation=ga_instance.best_solution_gen
eration))

# Saving the GA instance.
filename = 'genetic1'
ga_instance.save(filename=filename)

```

الملحق رقم (8)

الكود البرمجي للخوارزمية الجينية للحل الأمثل (الحالة 2+3)

```
import pygad
import numpy as np

desired_output = 0.0000000000000001

def fitness_func(solution, solution_idx):
    output = -3.545+0.000064*solution[0]+34.69*solution[1]-
0.598*solution[2]-
0.000421*solution[0]*solution[1]+0.000015*solution[0]*solution[2]+2.61*solu
tion[1]*solution[2]
    fitness = 1.0 / (np.abs(output - desired_output) + 0.000001)
    return fitness

num_generations = 100000
num_parents_mating = 2

sol_per_pop = 500
num_genes = 3

last_fitness = 0
def on_generation(ga_instance):
    global last_fitness
    print("Generation =
{generation}".format(generation=ga_instance.generations_completed))
    print("Fitness =
{fitness}".format(fitness=ga_instance.best_solution(pop_fitness=ga_instance.l
ast_generation_fitness)[1]))
    print("Change =
{change}".format(change=ga_instance.best_solution(pop_fitness=ga_instance.l
ast_generation_fitness)[1] - last_fitness))
    last_fitness =
ga_instance.best_solution(pop_fitness=ga_instance.last_generation_fitness)[
1]

ga_instance = pygad.GA(num_generations=num_generations,
                        num_parents_mating=num_parents_mating,
                        sol_per_pop=sol_per_pop,
                        num_genes=num_genes,
                        fitness_func=fitness_func,
                        on_generation=on_generation,

gene_space=[{'low':1274,'high':3822},{ 'low':0.05,'high':0.25},{ 'low':0.6,'h
igh':1.0}])

ga_instance.run()

ga_instance.plot_fitness()

solution, solution_fitness, solution_idx =
ga_instance.best_solution(ga_instance.last_generation_fitness)
```

```

print("Parameters of the best solution :
{solution}".format(solution=solution))
print("Fitness value of the best solution =
{solution_fitness}".format(solution_fitness=solution_fitness))
print("Index of the best solution :
{solution_idx}".format(solution_idx=solution_idx))

prediction = -3.545+0.000064*solution[0]+34.69*solution[1]-
0.598*solution[2]-
0.000421*solution[0]*solution[1]+0.000015*solution[0]*solution[2]+2.61*solu
tion[1]*solution[2]
print("Predicted output based on the best solution :
{prediction}".format(prediction=prediction))

if ga_instance.best_solution_generation != -1:
    print("Best fitness value reached after {best_solution_generation}
generations.".format(best_solution_generation=ga_instance.best_solution_gen
eration))

# Saving the GA instance.
filename = 'genetic2'
ga_instance.save(filename=filename)

```

Abstract

Surface smoothness is a critical characteristic that should be present in products, as many practical applications require a highly smooth surface to perform its desired function to the best possible performance. Surface roughness is an important indicator of material quality, and in manufacturing and production, it is crucial but difficult to measure surface roughness based on inputs such as rotation speed, feed rate and depth of cut. Some studies have shown that increasing the rotation speed or decreasing the depth of cut improves surface roughness. Therefore, this study was conducted to determine the effect of cutting parameters (rotation speed, feed rate, depth of cut) on surface roughness of AISI 1040 metal, which was chosen for its important and numerous uses in industry, such as couplings, bearings, crankshafts and more. It was observed that only decreasing the feed rate reduces surface roughness, while the optimal values of rotation speed and depth of cut cannot be determined to reduce surface roughness. Therefore, artificial intelligence algorithms (neural networks, linear regression, decision tree, random forest) were used, and a comparison was made between them to determine the best model capable of predicting surface roughness before performing the operation. It was observed that the performance of neural networks was better compared to linear regression, decision tree, and random forest. Genetic algorithms were then used to train the neural network, and the results showed that the neural network trained using genetic algorithms was better than the previous neural network. Genetic algorithms were also used to find the optimal parameters to improve surface smoothness, and the genetic algorithms were evaluated by using the parameters resulting from the genetic algorithms to run several new samples, and the results showed that the genetic algorithms gave better surface smoothness than the experimental samples.

Keywords: Turning, Surface Roughness, Artificial Intelligence, Neural Networks, Linear Regression, Decision Tree, Random Forest, Genetic Algorithms.

Syrian Arab Republic

Damascus University

Faculty of Mechanical & Electrical Engineering

Department of Mechanical Design Engineering



Improving Surface Smoothness in Turning Operations using Neural Networks and Genetic Algorithms

Thesis presented for a Master's degree in production automation engineering

By

Eng. Ahmad Alabedalhah

Supervisors

Prof. Mohammad Nader Zidan

Dr. Raouf Hamdan

Academic Year

2022-2023