

تقييم أداء خوارزميات الذكاء الصناعي للتنبؤ بخشونة السطح في عمليات الخراطة

احمد خالد العبدالحي*¹ محمد نادر زيدان² رؤوف حمدان³

*1. طالب ماجستير في قسم هندسة التصميم الميكانيكي _ كلية الهندسة الميكانيكية والكهربائية _ جامعة دمشق.

ahmad.alabedalhai@gmail.com

². دكتور، أستاذ في قسم هندسة التصميم الميكانيكي _ كلية الهندسة الميكانيكية والكهربائية _ جامعة دمشق.

MohammadZidan@damascusuniversity.edu.sy

³. دكتور، مدرس في قسم هندسة الحواسيب والأتمتة _ كلية الهندسة الميكانيكية والكهربائية _ جامعة دمشق.

RaoufHamdan@damascusuniversity.edu.sy

الملخص:

من الخصائص الهامة التي يجب أن تتوفر في المنتجات درجة نعومة أسطحها، حيث إن كثيراً من التطبيقات العملية تحتاج إلى أسطح على درجة عالية من النعومة حتى تؤدي الوظيفة المطلوبة منها بأفضل أداء ممكن. وتجدر 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) ولقد أشارت بعض الدراسات إلى أنه بزيادة سرعة الدوران أو بنقصان عمق القطع يتم تحسين خشونة السطح ولذلك تم دراسة تأثير بارامترات القطع (سرعة الدوران، معدل التغذية، عمق القطع) على معدن AISI1040 لمعرفة تأثير بارامترات القطع في عملية الخراطة وقد تم اختيار هذا المعدن لما له من استخدامات مهمة وعديدة في الصناعة من أهمها: المحامل، عمود المرفق وغيرها وتم التوصل إلى أن معدل التغذية هو فقط بنقصانه تقل خشونة السطح، بينما سرعة الدوران ومعدل التغذية لا يمكن معرفة قيمها المثلى لتقليل خشونة السطح، ولذلك قمنا باستخدام خوارزميات تعلم الآلة (الانحدار الخطي، شجرة القرار، الشبكات العصبونية، الغابة العشوائية) للتنبؤ بخشونة السطح قبل إجراء عمليات التشغيل وقد تم استخدام قيم حقيقية تم الحصول عليها من مخبر التصميم والتصنيع بمساعدة الحاسوب الموجود في كلية الهندسة الميكانيكية والكهربائية في جامعة دمشق، وقد تبين أن الشبكات العصبونية تعطي أفضل تنبؤ مقارنة مع شجرة القرار والانحدار الخطي والغابة العشوائية، مع إمكانية استخدام هذا النموذج للتنبؤ بخشونة السطح في المستقبل.

الكلمات المفتاحية: الخراطة، الذكاء الصناعي، تعلم الآلة، الانحدار الخطي، شجرة القرار، الشبكات العصبونية، الغابة العشوائية.

تاريخ الايداع: 2022/11/2

تاريخ القبول: 2023/1/17



حقوق النشر: جامعة دمشق –
سورية، يحتفظ المؤلفون بحقوق
النشر بموجب **CC BY-NC-SA**

Evaluation the performance of artificial intelligence algorithms to predict surface roughness in Turning processes

Ahmad Khaled Alabedalhαι*¹ Mohammad Nader Zidan² Raouf Hamdan³

*¹. Master's Student in the Department of Mechanical Design Engineering _ Faculty of Mechanical and Electrical Engineering _ Damascus University.

alabedalhαι@gmail.com .

². Professor in the Department of Mechanical Design Engineering _ Faculty of Mechanical and Electrical Engineering _ Damascus University.

MohammadZidan@damascusuniversity.edu.sy

³. Teacher in the Department of Computers and Automation Engineering _ Faculty of Mechanical and Electrical Engineering _ Damascus University.

RaoufHamdan@damascusuniversity.edu.sy

Received: 2/11/2022

Accepted: 17/1/2023



Copyright: Damascus University- Syria, The authors retain the copyright under a CC BY- NC-SA

Abstract:

An important characteristic of products must be the degree of smoothness of their surfaces, as many practical applications need surfaces on a high degree of smoothness in order to perform the required function as best as possible. Surface roughness is important in being a basic indicator for measuring material quality. In manufacturing and production processes, it is very important but difficult to know the surface roughness by relying on inputs (rotation speed, feed rate, depth of cut). Some studies have indicated that by increasing rotation speed or decreasing depth of cut the surface roughness is improved and therefore the impact of cutting parameters (rotation speed, feed rate, depth of cut) on metal has been studied AISI1040 to know the impact of cutting parameters in the turning process, this metal was selected because of its important and many uses in the industry, the most important of which are: bearings _ crankshaft etc. It was found that the feed rate is only by increasing the surface roughness is increased while the rotation speed and depth of cut Its optimal values cannot be known to reduce surface roughness. In order to find out the surface roughness before operations, we were able to use machine learning algorithms (linear regression, decision tree, neural networks, random forest) to predict surface roughness. Real values obtained from the computer assisted design and manufacturing laboratory at the Faculty of Mechanical and Electrical Engineering at Damascus University were used; Neural networks have been shown to give the best prediction compared to the decision tree, linear regression and random forest, With the possibility of using this model to predict the surface roughness in the future.

Keywords: Turning, Artificial intelligence, Machine learning, Linear regression, Decision tree, Neural network, c

المقدمة:

tree ويمكن تعريفها بأنها إحدى الأدوات الشائعة والقوية التي تُستخدم للتنبؤ بالبيانات أو الحدث وتصنيفها ولها بنية شجرة لذلك تم تسميتها بهذا الاسم، وتستخدم في مجالات واسعة لبساطتها وتم استخدامها للتنبؤ بالطقس[4]. وسنتناول في هذا البحث أيضاً الشبكات العصبونية (ANN) أو تسمى Deep neural network التي تعتبر من أقوى خوارزميات الذكاء الصناعي لما لها من قدرة على التنبؤ أو التصنيف. وهي مفضلة من قبل الباحثين كأسلوب تنبؤ قوي. وفي السنوات الأخيرة، أصبحت منتشرة في مجالات عدة وخاصة في نمذجة الأنظمة غير الخطية ويأتي تعدد استخدامات ANN في الغالب من قدرتها على التعلم من البيانات السابقة والقدرة على تحديث نفسها بناءً على الأخطاء [2]. ويبين الشكل (1) الشبكات العصبونية جزء من الذكاء الصناعي.

تعتبر المخرطة من أقدم الماكينات التي أنشأها الإنسان لتسهيل العمل. وتستخدم المخرطة حالياً في مختلف الصناعات الهندسية في مجالات الإنتاج الكبير والصغير لأجزاء الماكينات، وكذلك في ورش الصيانة المختلفة. وتحتاج المرحلة الحالية للتكنولوجيا إلي المخارط وكل ماكينات التشغيل التي تعمل بغاية من الدقة [1]. ومن أهم العوامل التي تؤخذ في الإعتبار أثناء عمليات التشغيل هي خشونة السطح. إن تكلفة عمليات التشغيل يمكن تقليلها بزيادة سرعة الدوران ومعدل التغذية ومع ذلك سرعة الدوران ومعدل التغذية تكون مقيدة بواسطة قيم دنيا وعليا [2]. ومع التقدم في تكنولوجيا الكمبيوتر ظهر الذكاء الصناعي¹، إنه من غير العملي إن لم يكن من المستحيل تطوير نموذج ذكاء صناعي بالإعتماد على جميع البارامترات المؤثرة على خشونة السطح. ومن خوارزميات الذكاء الصناعي المستخدمة في هذا البحث الانحدار الخطي Linear regression ويستخدم الانحدار الخطي للتنبؤ بالعلاقة بين متغيرين عن طريق تطبيق معادلة خطية على البيانات. ومبدأ الانحدار الخطي هو إيجاد علاقة تربط بين المدخلات ومخرج وحيد ورسم أفضل خط يربط بين المدخلات والمخرجات. ومن الأمثلة التي يستخدم فيها الانحدار الخطي: غالباً ما يستخدم الباحثون الطبيون الانحدار الخطي لفهم العلاقة بين جرعة الدواء وضغط الدم للمرضى وغيرها من الإستخدامات [3]. كما سنستخدم في هذا البحث خوارزمية شجرة القرار Decision

¹ قدرة الآلات والحواسيب الرقمية على القيام بمهام معينة تحاكي وتشابه تلك التي تقوم بها الكائنات الذكية؛ كالقدرة على التفكير أو التعلم من التجارب السابقة أو غيرها من العمليات الأخرى التي تتطلب عمليات ذهنية.

(2) هدف البحث:

- ❖ دراسة تأثير بارامترات القطع على خشونة السطح
- ❖ استخدام خوارزميات الذكاء الصناعي (الانحدار الخطي، شجرة القرار، الشبكات العصبونية، الغابة العشوائية) لمعرفة أي خوارزمية تعطي أقل خطأ.

(3) الدراسات المرجعية:

3_1 الدراسة المرجعية الأولى:

قام الباحث [5] Dolla Bhanu ,Prakash


بدراسة تأثير بارامترات القطع على خشونة السطح وتم تحديد 3 مراحل لكل من سرعة القطع ومعدل التغذية وعمق القطع وكانت نتيجة البحث عند دراسة تأثير ازدياد سرعة القطع كانت الخشونة تزداد ثم تعود للإنخفاض بينما عند دراسة تأثير ازدياد عمق القطع كانت الخشونة تزداد ثم تعود للإنخفاض بينما عند دراسة تأثير معدل التغذية كانت الخشونة تزداد بازدياد معدل التغذية.

3_2 الدراسة المرجعية الثانية:

قام الباحث [6] باستخدام الشبكات العصبونية للتنبؤ بخشونة السطح قبل إجراء عمليات التشغيل وأوضح الدراسة تقارب النتائج بين الشبكة العصبونية والنتائج التجريبية، وتم تشغيل 27 عينة على المخرطة لمعدن C38 وأداة قطع من نوع p20. تم استخدام لغة برمجة ماتلاب وبنية الشبكة تتألف من 3 طبقات:

- (1) طبقة مدخلات: سرعة القطع، معدل التغذية، عمق القطع
- (2) طبقة مخفية: تتألف من 10 عصبونات
- (3) طبقة خرج: تتألف من عصبون واحد هو الخشونة السطحية.

وبلغت قيمة MSE والتي تمثل متوسط الخطأ التربيعي بين القيم الحقيقية والقيم الناتجة عن الشبكة العصبونية لكامل العينات: 0.00096



الشكل (1) يبين العلاقة بين الذكاء الصناعي والشبكات العصبونية.

كما سنستخدم أيضاً خوارزمية الغابة العشوائية Random forest ويمكن تعريفها بسهولة على أنها خوارزمية قوية ومتعددة الاستخدامات للتعلم الآلي الخاضع للإشراف supervised learning وهي تجمع بين أشجار القرار المتعددة Decision trees لإنشاء «غابة». يمكن استخدامها لكل من مشاكل التصنيف classification والانحدار Regression. وسيتم في هذا البحث مقارنة هذه الخوارزميات مع بعضها لمعرفة أدق نموذج قادر على التنبؤ بخشونة السطح، بسبب كون نعومة السطح مطلب أساسي للمشغلين، لما لها من أهمية كبيرة في خواص المعدن، وعند زيادة خشونة السطح سوف ينتج:

1. الحصول على سطح كثير العيوب
2. زيادة الاحتكاك
3. تآكل المعدن
4. تأكسد المعدن
5. اهتراء المعدن
6. تعب المعدن
7. زيادة أو نقص في أبعاد قطع الشغل

العبدالحى، زيدان و حمدان


تقييم أداء خوارزميات الذكاء الصناعي للنتبؤ بخشونة السطح في عمليات الخراطة

2_4 الأجهزة المستخدمة:

مخرطة من نوع VICTOR TAICHUNG الموجودة في كلية الهندسة الميكانيكية والكهربائية _ جامعة دمشق وبين الشكل (3،4) المخرطة المستخدمة.



الشكل (3) المخرطة المستخدمة



الشكل (4) المخرطة مع توضع العينة العينة

3_3 الدراسة المرجعية الثالثة:

قام الباحث [2] بدراسة تأثير بارامترات القطع على خشونة السطح وأوضح النتائج أن معدل التغذية أكثر عامل له تأثير على خشونة السطح ثم قام الباحث باستخدام الانحدار الخطي للنتبؤ بخشونة السطح وقد بلغت قيمة $MSE = 0.4813$.

4_3 الدراسة المرجعية الرابعة:

قام الباحث [7] باستخدام طريقة تاجوشي للحل الأمثل لإيجاد البارامترات المثلى (سرعة القطع، معدل التغذية، عمق القطع) التي تعطي أقل قيمة لخشونة السطح ثم قام الباحث بتطبيق البارامترات الناتجة عن تاجوشي تجريبياً بتشغيل عينة جديدة وكانت خشونة السطح الناتجة ليست المثلى حيث يوجد بعض العينات التجريبية خشونة سطحها أقل من العينة الجديدة.

(4) المواد والأجهزة المستخدمة:

1_4 المواد المستخدمة:

❖ فولاذ كربوني AISI1040 ذو المواصفات التالية:
ويبين الجدول (1) التركيب الكيميائي للمعدن

الجدول (1) التركيب الكيميائي للمعدن

| C | Si | Mn | Cr | Mo | Ni | V | W | others |
|----------|-----------------|------|-----------------|----------------|------------|---|---|-------------------------|
| 0.4 1 | Ma x 0.40 | 0.65 | Ma x 0.40 | Ma x 0.1 | Max 0.4 | - | - | Cr+Mo +Ni Max0.63 |

❖ جهاز قياس خشونة السطح من نوع TR200 الموجود

في كلية الهندسة الميكانيكية والكهربائية _ جامعة دمشق

مبدأ عمل الجهاز:

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 بواسطة محول A/D.

ثم يتم تنقيح هذه الإشارات في المعالج الرئيسي باسم Ra. ويبين الشكل (5) جهاز TR200 أثناء قياس خشونة العينات بعد إجراء عملية الخراطة عليها.



الشكل (5) يبين الجهاز TR200 العينة الجهاز

❖ لقمة كربيدية NM4 -DNMG110408 المانية الصنع

من صنع شركة Walter الموضحة بالشكل (2).



الشكل (2) يبين اللقمة المستخدمة

تقييم أداء خوارزميات الذكاء الصناعي للتنبؤ بخشونة السطح في عمليات الخراطة

العبدالحى، زيدان و حمدان

الصنعي بالمستقبل والشكل (6) يبين العينات بعد إجراء عملية الخراطة. ثم قمنا بقياس خشونة السطح لكل عينة من خلال الجهاز الموضح بالشكل (5) حيث تم أخذ 3 قراءات للعينة الواحدة ثم أخذ المتوسط الحسابي لها كما ذكر في [2] والجدول (3) يبين العينات مع الخشونة السطحية لكل عينة والذي سنقوم باستخدامه لتدريب نموذج الذكاء الصناعي.

الجدول (2) يبين بارامترات القطع المستخدمة

| 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 |



الشكل (6) يبين العينات بعد إجراء عملية الخراطة

نطاق قياس الجهاز: Ra: 0,005 - 16 μ m

(5) العمل التجريبي:

نحتاج لبناء نموذج الذكاء الصناعي إلى قاعدة بيانات لتدريب النموذج ومن ثم سيتم التنبؤ بالخرج (خشونة السطح) بالإعتماد على المدخلات (سرعة الدوران، معدل التغذية، عمق القطع). وحسب المعدن المستخدم ونوع اللقمة المستخدمة [8] نستخدم الجدول الموضح بالشكل (2) أي حدود المدخلات هي: سرعة الدوران من القيمة 1274 إلى 3822 ومعدل التغذية من القيمة 0.18 إلى 0.25 بينما عمق القطع من القيمة 0.6 إلى 1.

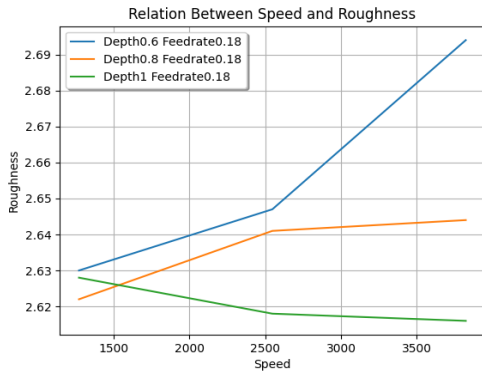
تم الحصول على العينات الموجودة في الجدول (3) من خلال التالي:

نثبت أولاً سرعة الدوران عند 1274 ومعدل التغذية عند 0.18 وتغيير عمق القطع حيث في العينة الأولى عمق القطع 0.6 وفي العينة الثانية 0.8

وفي العينة الثالثة 1 وبهذه الحالة حصلنا على 3 عينات بعد ذلك قمنا بتثبيت سرعة الدوران عند 1274 ومعدل التغذية قمنا بتثبيته عند 0.21 وتغيير عمق القطع حيث في العينة الرابعة يكون عمق القطع 0.6 وفي العينة الخامسة عمق القطع 0.8 والعينة السادسة 1 ثم بعد ذلك قمنا بتثبيت سرعة الدوران عند 1274 ومعدل التغذية عند 0.25 وتغيير عمق القطع حيث في العينة السابعة يكون عمق القطع 0.6 وفي العينة الثامنة 0.8 وفي العينة التاسعة 1 ثم نقوم بتثبيت سرعة الدوران عند 2548 ومعدل التغذية عند 0.18 وتغيير عمق القطع حيث في العينة العاشرة يكون عمق القطع 0.6 وفي العينة الحادية عشرة 0.8 وفي العينة الثانية عشرة 1 وهكذا حتى نحصل على 27 عينة مقسمة على 7 قطع تحتوي كل قطعة على عينتان فقط من كل طرف حيث بزيادة عدد العينات بالقطعة الواحدة من الممكن أن يحصل اهتزاز والذي يسبب خطأ في دقة القياس والذي بدوره يؤثر على دقة التنبؤ بخشونة السطح باستخدام نموذج الذكاء

2.63 بينما خشونة السطح عند سرعة الدوران 2548 أي العينة رقم (10) هي 2.647 بينما كانت خشونة السطح عند سرعة الدوران 3822 أي العينة رقم (19) هي 2.694 حيث نلاحظ بزيادة سرعة الدوران زادت خشونة السطح وتم رسم العلاقة بين سرعة الدوران و خشونة السطح كما هو مبين في الشكل (7) الخط البياني ذو اللون الأزرق. ثم بعد ذلك قمنا بتثبيت عمق القطع عند 0.8 ومعدل التغذية عند 0.18 وزيادة سرعة الدوران من القيمة 1274 ثم 2548 ثم 3822 أي العينات 2,11,20 حيث كانت خشونة السطح عند سرعة الدوران 1274 العينة (2) هي 2.622 بينما خشونة السطح عند سرعة الدوران 2548 العينة (11) هي 2.641 بينما خشونة السطح عند سرعة الدوران 3822 العينة (20) هي 2.644 حيث نلاحظ كذلك بزيادة سرعة الدوران زادت خشونة السطح كما هو مبين في الشكل (7) الخط البياني ذو اللون البرتقالي بينما عند تثبيت عمق القطع عند 1 ومعدل التغذية عند 0.18 وزيادة سرعة الدوران من القيمة 1274 ثم 2548 ثم 3822 أي العينات 3,12,21 حيث نلاحظ خشونة السطح عند القيمة 1274 هي 2.628 بينما عند 2548 هي 2.618 بينما عند القيمة 3822 هي 2.616 حيث نلاحظ أنه بزيادة سرعة الدوران انخفضت خشونة السطح وتم رسم هذه العلاقة في الشكل (7) الخط البياني ذو اللون الأخضر.

ومن هنا يمكن أن نستنتج لايوجد علاقة بين سرعة الدوران و خشونة السطح.



الشكل (7) تأثير سرعة الدوران على خشونة السطح

الجدول (3) يبين العينات بعد إجراء عملية قياس الخشونة


| رقم العينة | سرعة الدوران r.p.m | معدل التغذية mm/rev | عمق القطع mm | خشونة السطح 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 |

6) دراسة تأثير بارامترات القطع على خشونة السطح:

لمعرفة تأثير كل بارامتر على الخرج (خشونة السطح) عن طريق تثبيت البارامترات الأخرى وتغيير هذا البارامتر من خلال التالي:

6_1 دراسة تأثير سرعة الدوران على خشونة السطح:

قمنا بتثبيت معدل التغذية عند 0.18 وعمق القطع عند 0.6 وزيادة سرعة الدوران من القيمة 1274 ثم 2548 ثم 3822 أي تم أخذ العينات 1,10,19 حيث كانت خشونة السطح من الجدول (3) عند سرعة الدوران 1274 أي العينة رقم (1) هي



الشكل (8) يبين تأثير عمق القطع على خشونة السطح

3_6 دراسة تأثير معدل التغذية على خشونة السطح:

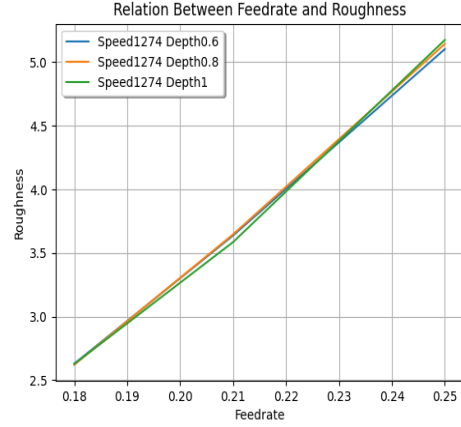
تم تثبيت سرعة الدوران عند 1274 وعمق القطع عند 0.6 وزيادة معدل التغذية من 0.18 ثم 0.21 ثم 0.25 أي العينات 1,4,7 ومن الجدول (3) نلاحظ أن خشونة السطح عند معدل التغذية 0.18 العينة (1) هي 2.63 بينما خشونة السطح عند معدل التغذية 0.21 هي 3.638 وكانت خشونة السطح عند معدل التغذية 0.25 هي 5.103 وبالتالي يمكن ملاحظة زيادة خشونة السطح بزيادة معدل التغذية وتم رسم هذه العلاقة في الشكل (9) الخط البياني ذو اللون الأزرق. ثم قمنا بتثبيت سرعة الدوران عند 1274 وعمق القطع عند 0.8 وزيادة معدل التغذية من 0.18 ثم 0.21 ثم 0.25 أي العينات 2,5,8 ومن الجدول (3) يمكن ملاحظة عند القيمة 0.18 العينة (2) كانت خشونة السطح 2.622 بينما عند معدل التغذية 0.21 العينة (5) كانت خشونة السطح 3.647 وخشونة السطح عند معدل التغذية 0.25 العينة (8) هي 5.144 وبالتالي نلاحظ زيادة خشونة السطح بزيادة معدل التغذية وتم رسم هذه العلاقة من خلال الشكل (9) الخط البياني ذو اللون البرتقالي. ثم قمنا بتثبيت سرعة الدوران عند 1274 وعمق القطع 1 وزيادة معدل التغذية من 0.18 ثم 0.21 ثم 0.25 أي العينات 3,6,9 ومن خلال الجدول (3) نجد أن خشونة السطح عند معدل التغذية 0.18 العينة (3) هي 2.628 بينما خشونة السطح عند معدل التغذية 0.21 العينة (6) هي 3.586 وخشونة السطح عند معدل التغذية 0.25 هي 5.175 وبالتالي زادت خشونة السطح بزيادة معدل التغذية وتم رسم هذه العلاقة من خلال الشكل (9) الخط البياني ذو اللون الأخضر.

2_6 دراسة تأثير عمق القطع على خشونة السطح:

تم تثبيت معدل التغذية عند 0.21 وسرعة الدوران عند 1274 وزيادة عمق القطع من القيمة 0.6 ثم 0.8 ثم 1 أي العينات 4,5,6 حيث كانت خشونة السطح عند عمق القطع 0.6 العينة (4) هي 3.638 بينما خشونة السطح عند 0.8 العينة (5) هي 3.647 وعند عمق القطع 1 العينة (6) هي 3.586 حيث نلاحظ زادت خشونة السطح ثم عادت للإنخفاض وتم رسم العلاقة ما بين خشونة السطح وعمق القطع في الشكل (8) الخط البياني ذو اللون الأزرق وعند تثبيت معدل التغذية عند 0.21 وسرعة الدوران 2548 وزيادة عمق القطع من 0.6 ثم 0.8 ثم 1 أي العينات 13,14,15 حيث كانت خشونة السطح عند عمق القطع 0.6 العينة 13 هي 3.663 بينما خشونة السطح عند عمق القطع 0.8 هي 3.593 وخشونة السطح عند عمق القطع 1 هي 3.604 حيث نلاحظ أنه بزيادة عمق القطع انخفضت خشونة السطح ثم عادت للإرتفاع وتم رسم العلاقة ما بين خشونة السطح وعمق القطع في الشكل (8) الخط البياني ذو اللون البرتقالي بينما عند تثبيت معدل التغذية عند 0.21 وسرعة الدوران عند 3822 وزيادة عمق القطع من القيمة 0.6 ثم 0.8 ثم 1 أي العينات 22,23,24 ومن الجدول (3) نلاحظ أن خشونة السطح عند القيمة 0.6 العينة 22 هي 3.501 بينما خشونة السطح عند القيمة 0.8 هي 3.555 وخشونة السطح عند 1 هي 3.598 حيث بزيادة عمق القطع زادت خشونة السطح وتم رسم العلاقة ما بين خشونة السطح وعمق القطع في الشكل (8) الخط البياني ذو اللون الأخضر. ومن هنا يمكن ملاحظة لا يوجد علاقة ما بين خشونة السطح وعمق القطع.

تقييم أداء خوارزميات الذكاء الصناعي للتنبؤ بخشونة السطح في عمليات الخراطة من خلال ماسبق يمكن استنتاج أن خشونة السطح تزداد بزيادة معدل التغذية. وبالتالي يصبح عدد العينات:

18 عينة للتدريب و3 عينات للتقييم و6 عينات للإختبار. تقوم الخوارزمية بإختيار العينات بشكل عشوائي من الجدول (3) للتدريب بشكل أفضل. وتحتاج كل خوارزمية إلى مدخلات وهي في حالتنا هذه (سرعة الدوران، معدل التغذية، عمق القطع) والخرج هو (خشونة السطح). ولتقييم دقة كل خوارزمية سنقوم باستخدام متوسط الخطأ التربيعي Mean squared error اختصاراً MSE لعينات الإختبار (6 عينات) التي لم يراها النموذج من قبل ويقوم بحساب متوسط الخطأ التربيعي لخشونة السطح من الجدول (3) وخشونة السطح الناتجة من الخوارزمية.



الشكل (9) يبين تأثير معدل التغذية على الخشونة

المعادلة المستخدمة:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

حيث:

MSE: متوسط الخطأ التربيعي

n: عدد العينات

Y_i : القيمة الحقيقية للخشونة

\hat{Y}_i : القيمة المتنبأ بها للخشونة

1_7 الإنحدار الخطي Linear regression

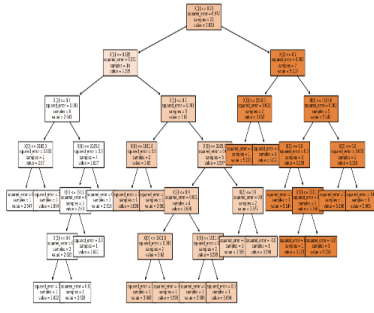
قمنا بحساب متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الإختبار (6 عينات) أي الفرق بين القيم الحقيقية لخشونة السطح من الجدول (3) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته $MSE = 0.00856$ والشكل (10) يبين كل عينة مع خشونة السطح الحقيقية والموافقة لها الموجودة على الشكل بإسم "Actual" وكل عينة مع خشونة السطح المتنبأ بها الموجودة على الشكل بإسم "predicted".

من خلال ماسبق نستنتج أنه فقط معدل التغذية يمكن معرفة قيمته المثلى للحصول على سطح ناعم (حيث بنقصان معدل التغذية تقل خشونة السطح) بينما سرعة الدوران وعمق القطع لايمكن معرفة القيمة المثلى له للحصول على سطح ناعم لذلك سنقوم باستخدام خوارزميات الذكاء الصناعي للتنبؤ بخشونة السطح (الخرج) قبل إجراء عملية التشغيل على المخرطة مع إعطاء المدخلات (سرعة الدوران _ معدل التغذية _ عمق القطع).


7 خوارزميات الذكاء الصناعي:

سنقوم في هذا الجزء باستخدام 4 طرق للتنبؤ بخشونة السطح بالإعتماد على لغة Python كونها من أفضل لغات البرمجة في هذا المجال ولسهولة تعلمها، وتحتوي العديد من المكتبات التي تسهل كتابة الكود البرمجي.


جميع الخوارزميات تحتاج الى عينات تدريب (لتدريب النموذج) وعينات تقييم (لتقييم أداء النموذج أثناء عملية التدريب) وعينات اختبار لإختبار النموذج بعد عملية التدريب، حيث تم تقسيم العينات من الجدول (3) إلى 80% عينات تدريب و20% عينات اختبار وعينات التدريب يتم تقسيمها إلى



الشكل (11) هيكل شجرة القرار



الشكل (10) الفرق بين القيم الحقيقية والمتنبأ بها باستخدام الإنحدار الخطي.



الشكل (12) يبين الفرق بين القيم الحقيقية والمتنبأ بها باستخدام شجرة القرار

3_7 الشبكات العصبونية:

الشبكة العصبونية المستخدمة تتألف من:

- (1) طبقة مدخلات (سرعة الدوران _ معدل التغذية _ عمق القطع).
- (2) طبقة مخفية واحدة تحتوي على 300 عصبون.
- (3) طبقة خرج (خشونة السطح).

ويبين الشكل (13) الشبكة العصبونية المستخدمة:

2_7 شجرة القرار Decision tree:

شجرة القرار تتعلم عن طريق الإنقسام الى مجموعات فرعية وتتابع عملية الانقسام حتى الوصول إلى أقل قيمة للخطأ لايمكن بعدها الانقسام والوصول الى أقل من قيمة الخطأ الحالي فتتوقف الشجرة عن الانقسام[4]. ويبين الشكل (11) عملية الإنقسام، حيث في البداية كان الخطأ 0.23 ثم بدأت الشجرة بالإنقسام والتكرار حتى الوصول إلى أقل قيمة للخطأ. ثم قمنا بحساب متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الإختبار (6 عينات) أي الفرق بين القيم الحقيقية لخشونة السطح من الجدول (3) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته


$MSE = 0.00574$. ويبين الشكل (12) كل عينة مع خشونة السطح الحقيقية الموافقة لها الموجودة على الشكل بإسم "Actual" وكل عينة مع خشونة السطح المتنبأ بها الموجودة على الشكل بإسم "predicted".

تقييم أداء خوارزميات الذكاء الصناعي للتنبؤ بخشونة السطح في عمليات الخراطة

العبدالحى، زيدان و حمدان

الجدول (3) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته

$MSE = 0.00162$. ويبين الشكل (14) كل عينة مع خشونة السطح الحقيقية الموافقة لها الموجودة على الشكل بإسم "Actual" وكل عينة مع خشونة السطح المتنبأ بها الموجودة على الشكل بإسم "predicted". ونلاحظ من الشكل (14) مدى التطابق بين القيم الحقيقية والمتنبأ بها.



الشكل (14) يبين الفرق بين القيم الحقيقية والمتنبأ بها باستخدام الشبكات العصبونية


7_4 الغابة العشوائية Random forest:

الغابة العشوائية هي خوارزمية تعلم آلي خاضعة للإشراف وهي تجمع بين أشجار القرار Decision trees للوصول إلى نتيجة واحدة. تتكون خوارزمية الغابة العشوائية من العديد من أشجار القرار، والتنبؤ يتم عن طريق أخذ متوسط الناتج من الأشجار المختلفة [10].

البارامترات التي يجب تحديدها للغابة العشوائية:

(1) عدد الأشجار: حيث تم ملاحظة بزيادة عدد الأشجار للغابة العشوائية تزداد دقة التنبؤ حتى الوصول إلى عدد الأشجار 6.

ويبين الشكل (15) الشجرة الأولى والشكل (16) الشجرة الثانية وهكذا...، وتتعلم الشجرة عن طريق الإنقسام والتكرار حتى الوصول إلى أقل قيمة للخطأ MSE وكما في حالة الانحدار الخطي وشجرة القرار والشبكات العصبونية قمنا بحساب متوسط



الشكل (13) الشبكة العصبونية المستخدمة

حيث:

Input layer: طبقة المدخلات (سرعة الدوران _ معدل التغذية _ عمق القطع).

Hidden layer: طبقة مخفية واحدة تحتوي على 300 عصبون.

Output layer: طبقة الخرج (خشونة السطح).

يوجد أيضاً بعض البارامترات التي يجب تحديدها للشبكة العصبونية:

(1) عدد الطبقات المخفية: طبقة واحدة


(2) عدد العصبونات في الطبقة المخفية: تم تحديد عدد العصبونات في الطبقة المخفية عن طريق التجريب ثم نقوم باختيار أفضل عدد العصبونات التي تعطي أقل قيمة للخطأ MSE تم استخدام 300 عصبون.

(3) عدد مرات التكرار epochs: أي هي عدد مرات معالجة كافة عينات التدريب تم استخدام 600,000.

(4) Activation function: تقوم بتحويل المدخلات إلى خرج، تم استخدام تابع Relu وهو تابع غير خطي ويعمل بشكل جيد كتابع تنشيط.

(5) optimizer: تقوم بتعديل الأوزان والتي تعطي أقل قيمة للخطأ، تم استخدام خوارزمية (SGD).

وكما في حالة الانحدار الخطي وشجرة القرار قمنا بحساب متوسط الخطأ التربيعي MSE لخشونة السطح لعينات الإختبار (6 عينات) أي الفرق بين القيم الحقيقية لخشونة السطح من



الشكل (17) يبين الفرق بين القيم الحقيقية والمتنبأ بها باستخدام الغابة العشوائية

8) النتائج والمناقشة:

يمكن تلخيص النتائج التي حصلنا عليها بالتالي:


(1) من الشكل (7) نلاحظ عند تثبيت عمق القطع عند 0.6 ومعدل التغذية عند 0.18 زادت الخشونة بازدياد سرعة الدوران ولكن عند تثبيت عمق القطع عند 1 ومعدل التغذية عند 0.18 انخفضت خشونة السطح بازدياد سرعة الدوران وهذا يتفق مع [11].

(2) من الشكل (8) نلاحظ عند تثبيت سرعة الدوران عند 1274 ومعدل التغذية عند 0.21 وزيادة عمق القطع الخشونة ازدادت ثم عادت للانخفاض.

(3) من الشكل (9) نلاحظ تزداد خشونة السطح بازدياد معدل التغذية وهذا يتفق مع [6].

(4) متوسط الخطأ التربيعي (الفرق بين القيم الحقيقية والقيم المتنبأ بها) للانحدار الخطي بلغت قيمته 0.00856 $MSE =$ وهي قيمة أفضل مما ذكر في [2]. بينما قد بلغت قيمة متوسط الخطأ التربيعي لشجرة القرار $MSE = 0.00574$ وقيمة متوسط الخطأ التربيعي للشبكة العصبونية $MSE = 0.00162$ ولكن في [6] فقد توصل الباحثون إلى قيمة $MSE = 0.00067$. بينما كانت قيمة متوسط الخطأ التربيعي عند استخدام الغابة العشوائية $MSE = 0.00472$.

تقييم أداء خوارزميات الذكاء الصناعي للتنبؤ بخشونة السطح في عمليات الخراطة الخطأ التربيعي MSE لخشونة السطح لعينات الإختبار (6 عينات) أي الفرق بين القيم الحقيقية لخشونة السطح من الجدول (3) وبين قيمة خشونة السطح الناتجة من الخوارزمية وقد بلغت قيمته $MSE = 0.00472$. ويبين الشكل (17) كل عينة مع خشونة السطح الحقيقية الموافقة لها الموجودة على الشكل بإسم "Actual" وكل عينة مع خشونة السطح المتنبأ بها الموجودة على الشكل بإسم "predicted".



الشكل (15) يبين الشجرة الأولى



الشكل (16) يبين الشجرة الثانية

تقييم أداء خوارزميات الذكاء الصناعي للتنبؤ بخشونة السطح في عمليات الخراطة

العبدالحى، زيدان و حمدان

(9) الاستنتاجات:

تدريب الشبكة وتقليل عدد المحاولات epochs وعند تكبير

(1) يمكن الحصول على سطح ناعم بانخفاض معدل

المجال من الممكن الحصول على نعومة سطح أفضل.

التغذية

(2) إيجاد طريقة لاختيار القيم المثلى للعوامل التي تحتاج لعدد

(2) أفضل خوارزمية للتنبؤ بخشونة هي الشبكات

كبير من المحاولات مثل: عدد العصبونات _ عدد المحاولات

العصبونية (كونها أعطت أقل قيمة لمتوسط الخطأ التربيعي

epochs وغيرها...

(MSE) ثم الغابة العشوائية ثم شجرة القرار ثم الإنحدار الخطي.

(3) تجريب طرق أخرى من خوارزميات تعلم الآلة لمحاولة إيجاد

(10) التوصيات:

طريقة تعطي قيمة خطأ أفضل من الشبكات العصبونية.

(1) زيادة عدد العينات عن طريق استخدام 4 أو 5 مراحل لكل

(4) البحث عن خوارزمية من الذكاء الصناعي تعطي الحل

الأمثل لبارامترات القطع وتكون أفضل من أداء طريقة تاجوشي

من بارامترات القطع (سرعة الدوران _ معدل التغذية _ عمق

للحل الأمثل كونها لم تعطي القيمة المثلى التي كان الباحث

القطع) وبالتالي تدريب الشبكة على بيانات أكثر وبالتالي

يتوقعها كما ذكر في [7].

تحسين أداء الشبكة كما ذكر في [12]. ومن الممكن زيادة سرعة

التمويل: هذا البحث ممول من جامعة دمشق وفق رقم

التمويل(501100020595).

References :

- surface roughness steel. Turkish J. Nat. Sci., 5(1), 29-36.
12. Gadelmawla, E. S., Koura, M. M., Maksoud, T. M., Elewa, I. M., & Soliman, H. H. (2002). Roughness parameters. *Journal of materials processing Technology*, 123(1), 133-145.
 13. Rao, C. J., Rao, D. N., & Srihari, P. (2013). Influence of cutting parameters on cutting force and surface finish in turning operation. *Procedia Engineering*, 64, 1405-1415.
 14. Ghani, J. A., Choudhury, I. A., & Hassan, H. H. (2004). Application of Taguchi method in the optimization of end milling parameters. *Journal of materials processing technology*, 145(1), 84-92.
 15. Rokach, L., & Maimon, O. (2005). Decision trees. In *Data mining and knowledge discovery handbook* (pp. 165-192). Springer, Boston, MA.
 1. منقريوس، عبد المسيح. تكنولوجيا الخراطة تخصص تشغيل معادن.
 2. Asiltürk, İ. (2012). Predicting surface roughness of hardened AISI 1040 based on cutting parameters using neural networks and multiple regression. *The International Journal of Advanced Manufacturing Technology*, 63(1), 249-257
 3. Sen, A., & Srivastava, M. (1990). Multiple regression. In *Regression Analysis* (pp. 28-59). Springer, Berlin, Heidelberg.
 4. Petre, E. G. (2009). A decision tree for weather prediction. *Universitatea Petrol-Gaze din Ploiesti*, 61(1), 77-82.
 5. 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)*, 7(6), 114-122.
 6. Boukezzi, F., Nouredine, R., Benamar, A., & Nouredine, 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.
 7. Dahbi, S., El Moussami, H., & Ezzine, L. (2015, December). Optimization of turning parameters for surface roughness. In *Xème Conférence Internationale: Conception et Production Intégrées*.
 8. Walter General Catalog..(2018).North America.
 9. Moolayil, J., Moolayil, J., & John, S. (2019). *Learn Keras for deep neural networks* (pp. 33-35). Birmingham: Apress
 10. Cutler, A., Cutler, D. R., & Stevens, J. R. (2012). Random forests. In *Ensemble machine learning* (pp. 157-175). Springer, Boston, MA.
 11. Erçetin, A., & Usca, Ü. A. (2016). An experimental investigation of effect of turning AISI 1040 steel at low cutting speed on tool wear and