

دراسة إمكانية استخدام خوارزميات تعليم الآلة للتنبؤ بالجودة وبارامترات المعالجة لنمذجة

الترسيب المنصهر (FDM)

علي سلمان بركات^{1*} وسيم جنيدي²

^{1*}. طالب ماجستير علوم ويب في الجامعة الافتراضية السورية.

Ali-134070@svuonline-org

². دكتور في الشبكات اللاسلكية في الجامعة الافتراضية السورية.

WaseemJuneidi@damascusuniversity.edu.sy

الملخص:

تعد نمذجة الترسيب المنصهر (FDM) Fused deposition modeling أحد أشهر أنواع التصنيع الإضافي Additive Manufacturing، والتي تتميز بقلّة التكاليف وسرعة الإنتاج، لكن هذا النوع يحتوي على العديد من بارامترات التصنيع (أكثر من 20 بارامتر)، إن أي تغيير في قيم البارامترات له تأثيره المباشر على جودة الإنتاج والخصائص الميكانيكية، وقد تم الاعتماد في الدراسات السابقة على المنهج التجريبي لبيان تأثير بارامترات المعالجة على جودة المنتج، تم تنفيذ هذه المقالة لإظهار إمكانية استخدام خوارزميات تعليم الآلة في التنبؤ بأحد معايير جودة المنتج وهو قوة الشد (tensile strength) اعتماداً على بارامترات المعالجة، وكذلك التنبؤ بنوع المادة الواجب استخدامها للتصنيع اعتماداً على قيم معينة لباقي البارامترات.

الكلمات المفتاحية: التشكيل بالترسيب المنصهر، تعليم الآلة، التصنيع التجمعي، بارامترات لمعالجة قوة الشدائد.

تاريخ الايداع: 2022/9/20

تاريخ القبول: 2022/19/ 17



حقوق النشر: جامعة دمشق -
سورية، يحتفظ المؤلفون بحقوق
CC النشر بموجب الترخيص
BY-NC-SA 04

Studying the possibility of using machine learning algorithms to predict quality and processing parameters for Fused Deposition Modeling (FDM)

Ali Slman Barakat^{*1} Waseem Juneidi²

^{*1}.Master of web science in Syrian Virtual University.

Ali-134070@svuonline-org

². PhD in Wireless Networking in Syrian Virtual University.
WaseemJuneidi@damascusuniversity.edu.sy

Abstract:

Fused deposition modeling (FDM) is one of the most popular types of additive manufacturing, which is characterized by low costs and fast production, but this type contains many processing parameters (more than 20 parameters), Any change in the values of these parameters has a direct impact on the quality of production and mechanical properties, and previous studies were relied on the experimental method to show the effect of processing parameters on product quality. This article was implemented to show the possibility of using machine learning algorithms in predicting one of the product quality standards. It is the tensile strength, depending on the processing parameters, as well as the prediction of the type of material to be used for manufacturing based on certain values for the rest of the parameters.

Keywords: Fused deposition modeling, machine learning, additive manufacturing, processing parameters, tensile strength.

Received: 20/9/2022

Accepted: 17/19/2022



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

1- المقدمة:

برنامج كمبيوتر باستخدام البيانات المجمعة ، لحل مشكلة معينة وتحسين كفاءة البرنامج تلقائيًا . في السنوات الأخيرة ، تم تطوير العديد من تطبيقات تعليم الآلة ، مثل اكتشاف المعاملات المصرفية الاحتيالية، وأنظمة تصفية المعلومات التي تتعلم من تفضيلات القراءة للمستخدم ، والدراسات النيولوجية العصبية ، والمركبات المستقلة التي تتعلم القيادة على الطرق السريعة. وفي الوقت نفسه أيضًا ، كان هناك تقدم مهم في المفاهيم والخوارزميات التي تشكل أساس التعلم الآلي. [2]

2- الدراسات السابقة

اعتمدت أغلب الدراسات السابقة المتعلقة بالتصنيع التجميعي من النوع FDM على الدراسة التجريبية لتأثير أحد بارامترات التصنيع على أحد معايير جودة المنتج وهو قوة الشد (tensile strength)، يحوي (الجدول 1) لائحة ببعض الدراسات التي اعتمدت المنهج التجريبي، مع البارامترات المتغيرة التي تم دراسة تأثيرها على جودة التصنيع ضمن كل دراسة.

يعتبر التشكيل بالترسيب المصهور Fused deposition modeling (FDM) هو أحد أنواع الصناعات التجميعية Additive Manufacturing، يتم من خلالها تمرير المادة المصهورة عبر فوهة، حيث تسخن وترسب طبقة طبقة، تتحرك الفوهة بشكل أفقي بينما تتحرك المنصة التي تحمل الغرض بشكل عمودي، [1] وهذه التقنية تستخدم في عديد من الطابعات منخفضة التكلفة المستخدمة حاليا. تتميز هذه الطريقة بإمكانية الاستخدام السهل للبلاستيك من نوع ABS (Acrylonitrile Butadiene Styrene) أو PLA(PolyLactic Acid) والتي يمكن ان تنتج أغراض قريبة بشكل كبير من النموذج المطلوب وبمواصفات جيدة. يوجد عوامل تؤثر على جودة التصنيع مثل حجم وشكل الفوهة، [1] ويمكن تحسين التصنيع بزيادة الحرارة واستخدام مادة صمغية.

تعليم الآلة هو حقل فرعي من الذكاء الاصطناعي (Artificial Intelligence) AI، ويستخدم لاستكشاف بنية البيانات وتناسبها مع النماذج التي يمكن فهمها واستخدامها من قبل المستخدمين، ويجب على السؤال حول كيفية إنشاء

البارامترات التي تم دراستها	اسم المرجع
raster angle(degree)- layer thickness(mm)- raster width(um)	المرجع [3]
percentage infill (%) -layer height(mm)- raster angle(degree)	المرجع [4]
raster angle(degree)- layer thickness(mm) -material type	المرجع [5]
Layer thickness (mm)- Deposition velocity (mm/s)- Air gap (mm)	المرجع [6]
Raster angle(degree)-Layer height(um)-Raster width(um)	المرجع [7]
Layer thickness (mm)-Orientation angle (degree)-Shell thickness (mm)	المرجع [8]
Infill density (%) -Temperature (C) -Speed (mm/s)	المرجع [9]
Build orientation -Raster orientation (degree)- Nozzle diameter(mm)- Extruder temperature (c)-Infill rate (%) - Number of the shells - Extruding speed (mm/s)- Layer height (mm)	المرجع [10]
infill density (%) -layer thickness (mm)- part orientation (degree)	المرجع [11]

الجدول (1): لائحة ببعض الدراسات التي اعتمدت المنهج التجريبي

كافة الدراسات المذكورة تعتمد المنهج التجريبي للاستنتاج، أي يتم تصميم عدة عينات (من 9 عينات إلى 36 عينة كحد أقصى)، وهذه العينات متشابهة من حيث الشكل ومختلفة من حيث بارامترات التصنيف، ثم يتم اختبار جودة المنتج واستنتاج تأثير هذه البارامترات على جودة المنتج، ولكن هذه المنهجية تعتبر غير شاملة من حيث النتائج لقلة عدد الاختبارات أو العينات لكل دراسة.

3- بعض أنواع خوارزميات تعليم الآلة:

- الانحدار الخطي (Linear regression): هو طريقة شائعة لتحليل البيانات الموصوفة في نموذج خطي بطبيعته، وهو محاولة لنمذجة العلاقة بين متغيرين من خلال ملائمة معادلة خطية للبيانات المرصودة . [2]

-انحدار ridge (ridge regression): هو طريقة ضبط نموذج تُستخدم لتحليل أي بيانات تعاني من العلاقات الخطية المتعددة. عند حدوث مشكلة العلاقة الخطية المتعددة، تكون المربعات الصغرى غير متحيزة، وتكون التباينات كبيرة، وينتج عن ذلك أن تكون القيم المتوقعة بعيدة عن القيم الفعلية. [2]

- انحدار lasso (Lasso regression): هو نوع من الانحدار الخطي يستخدم الانكماش. الانكماش هو المكان الذي يتم فيه تقليص قيم البيانات باتجاه نقطة مركزية، مثل المتوسط. يشجع إجراء lasso النماذج البسيطة والمتفرقة (أي النماذج ذات المعلمات الأقل). هذا النوع المعين من الانحدار مناسب تمامًا للنماذج التي تعرض مستويات عالية من الخطية الخطية أو عندما تريد أتمتة أجزاء معينة من اختيار النموذج، مثل التحديد المتغير / حذف المعلمة. [2]

- خوارزمية شجرة القرار Tree Decision Regressor: الغرض من بناء شجرة قرار هو التنبؤ بالمتغير المستهدف بناءً على متغير الإدخال من خلال تعلم قواعد القرار، حيث تُستخدم أشجار القرار بشكل شائع لبيانات التصنيف و الانحدار. [2]

- خوارزمية Support Vector Machine SVM: هي واحدة من أشهر الخوارزميات التي تفصل بين فئتين. تتميز بإمكانية إجراء التصنيف الخطي، وإدارة البيانات غير الخطية بكفاءة باستخدام طريقة تُعرف باسم وظيفة kernel والتي بدورها تقوم بتعيين مدخلات المتجه إلى مساحة ميزة عالية الأبعاد. تعتبر نظرية التعلم الإحصائي أساساً ل SVM. [2]

- خوارزمية K-nearest Neighbors Regression: [12] انحدار KNN هو طريقة تحسب الارتباط بين المتغيرات المستقلة والنتيجة المستمرة عن طريق حساب متوسط الأبعاد في نفس المجموعة. يجب تعيين حجم المجموعة من قبل المحلل أو يمكن اختياره باستخدام التحقق المتقاطع لتحديد الحجم الذي يقلل من متوسط الخطأ التربيعي.

- خوارزمية Random Forest Regression [13]: هي خوارزمية تعلم خاضعة للإشراف تستخدم طريقة تعلم المجموعة للانحدار. طريقة تعلم المجموعة هي تقنية تجمع بين التنبؤات من خوارزميات متعددة للتعلم الآلي لعمل تنبؤ أكثر دقة من نموذج واحد.

4- منهجية العمل:

سيتم في هذه الدراسة التحقق من إمكانية استخدام خوارزميات تعليم الآلة لتحسين بارامترات المعالجة لصناعة) نمذجة الترسيب المنصهر (FDM)، حيث تم العمل على مرحلتين:

1- التنبؤ بقيمة بارامتر معالجة اعتماداً على قيم معينة لباقي البارامترات.

2- التنبؤ بجودة المنتج اعتماداً على بارامترات المعالجة.

لتقييم الخوارزميات سيتم المقارنة بين القيم التالية لكل خوارزمية:

1- MAE (Mean Absolute Error):

دراسة استخدام خوارزميات تعليم الآلة للتنبؤ بالجودة....

هو متوسط المسافة العمودية بين كل قيمة فعلية والخط الذي يطابق البيانات بشكل أفضل.

2- RMSE (Root Mean Square Error): هو الجذر التربيعي لمتوسط المسافة التربيعية بين النتيجة الفعلية والنتيجة المتوقعة.

3-R2-score: هو مدى نجاح نموذج الانحدار في شرح البيانات المرصودة

في هذه الدراسة تم استخدام برنامج jupyter for python للتأكد من النتائج، كما تم استخدام كتلة بيانات حقيقية 50 عينة من موقع Kaggle [14] وهذه البيانات تحوي 12 ميزة، حيث ظهرت الحاجة لهذه الكتلة من البيانات بسبب ضرورة وجود بيانات حقيقية وكاملة، والحصول على نتائج صحيحة،

تظهر الأعمدة وجزء من البيانات في (الشكل 1).

```
In [2]: datapd.read_csv("../data.csv")
data.head()
```

	layer_height	wall_thickness	infill_density	infill_pattern	nozzle_temperature	bed_temperature	print_speed	material	fan_speed	roughness	tensile_strength
0	0.02	8	90	grid	200	60	40	abs	0	20	10
1	0.02	7	80	honeycomb	205	65	40	abs	25	32	10
2	0.02	1	80	grid	230	70	40	abs	60	40	0
3	0.02	4	70	honeycomb	240	75	40	abs	75	60	10
4	0.02	6	90	grid	260	80	40	abs	100	92	5

```
In [3]: data.shape
Out[3]: (50, 12)
```

الشكل (1): جزء من الأعمدة والبيانات المستخدم

يمكن استخدام خوارزميات التنبؤ لتحديد قيمة بارامتر اعتماداً على قيم باقي البارامترات، وكمثال سيتم التنبؤ بنوع المادة الواجب استخدامها للوصول إلى خصائص معينة، تحوي البيانات المتوفرة مادتين أساسيتين هما PLA,ABS أي أننا سنعتبر مصفوفة الدخل هي 11 بارامتر (layer_height , wall_thickness, infill_density, 'nozzle_temperature', bed_temperature, 'print_speed', fan_speed, roughness, tensile_strength, elongation, infill_pattern,) ومصفوفة الخرج هي نوع المادة material.

بركات و جنيدي

قبل بدء العمل يجب أن يتم تنفيذ معالجة مسبقة للبيانات وذلك من خلال:

1- تحويل الأعمدة النصية إلى رقمية عن طريق الاجرائية LabelEncoder لتصبح البيانات السابقة كتلة بيانات رقمية.
2- الملاءمة بين البيانات وجعلها ذات مجال قيم واحد باستخدام التابع StandardScaler.

تم كتابة إجرائية modelTest2 التي تساعد في عملية تقييم الخوارزميات لاختيار الخوارزمية والبارامترات الأفضل.

عمل الاجرائية: تقوم هذه الاجرائية بإيجاد أفضل مجموعة من المعاملات لتطبيقها على خوارزمية التنبؤ ثم يتم تقسيم كتلة البيانات الكلية إلى بيانات اختبار وبيانات تدريب، وفي حالة كتلة البيانات التي يتم الاختبار عليها يوجد (50 عينة) يتم تقسيمها إلى بيانات تدريب (40 عينة) ثم يتم اختبار النتائج على بيانات الاختبار (10 عينات)، بعدها يتم إظهار نتائج اختبار الخوارزمية على بيانات الاختبار.

دخل الإجرائية:

modelName: يمثل اسم خوارزمية التنبؤ بشكل نصي ويتم استخدامه في عملية اظهار النتائج.

Model: يمثل خوارزمية التنبؤ التي سيتم استخدامها في الاجرائية.

params_grid: مصفوفة من المعاملات التي سيتم من خلالها اختيار أفضل المعاملات.

x_train, y_train: بيانات تعليم الخوارزمية، بداية يتم اختبار الخوارزمية لإيجاد أفضل مجموعة من المعاملات.

خرج الاجرائية: تعطي الاجرائية خرج نصي يظهر أفضل المعاملات التي يمكن استخدامها مع خوارزمية التنبؤ بالاضافة إلى المعلومات التالية: .bestscore, RMSE, MAE, r2_score

```
Ridge >> RMSE: 0.061502858283018005
Ridge >> MAE: 0.047956919186445804
Ridge >> r2_score: 0.980808587316003
```

1-1-4- استعراض النتائج:

- تم استخدام الاجرائية modelTest2 لاختبارها على الخوارزميات التالية: SVR, LassoCV, Lasso, RandomForestRegression, Ridge, LinearRegression, KNeighborsRegressor, DecisionTreeRegressor, وكانت النتائج كما يلي:

```
Lasso >> best parameters: {'alpha': 0.02}
Lasso >> best score: -0.010898015927201812
Lasso >> RMSE: 0.09966783969286216
Lasso >> MAE: 0.08164530221177455
Lasso >> r2_score: 0.935085612513493
```

```
SVR >> best parameters: {'C': 100, 'gamma': 0.001, 'kernel': 'rbf'}
SVR >> best score: -0.009767214419958063
SVR >> RMSE: 0.08662865162750602
SVR >> MAE: 0.07154256863542088
SVR >> r2_score: 0.9551832141349018
```

```
KNeighborsRegressor >> best parameters:
{'n_neighbors': 5, 'weights': 'distance'}
KNeighborsRegressor >> best score: -0.11503337420051411
KNeighborsRegressor >> RMSE: 0.48068438493257076
KNeighborsRegressor >> MAE: 0.3995244756770441
KNeighborsRegressor >> r2_score: 1.8966495716161198
```

```
RandomForestRegressor >> best parameters:
{'bootstrap': False, 'max_features': 'auto', 'min_samples_split': 2, 'n_estimators': 10}
RandomForestRegressor >> best score: -0.00019999999999999999
RandomForestRegressor >> RMSE: 0.0
RandomForestRegressor >> MAE: 0.0
RandomForestRegressor >> r2_score: 1.0
```

```
DecisionTreeRegressor >> best parameters:
{'criterion': 'mse', 'max_depth': 3, 'max_features': None, 'max_leaf_nodes': None, 'min_samples_leaf': 1, 'min_samples_split': 2, 'min_weight_fraction_leaf': 0, 'random_state': None, 'splitter': 'best'}
DecisionTreeRegressor >> best score: 0.0
DecisionTreeRegressor >> RMSE: 0.0
DecisionTreeRegressor >> MAE: 0.0
DecisionTreeRegressor >> r2_score: 1.0
```

```
LinearRegression >> best parameters: {'copy_X': True, 'fit_intercept': True, 'normalize': False}
LinearRegression >> best score: -0.009215450469252935
LinearRegression >> RMSE: 0.06083169892817757
LinearRegression >> MAE: 0.04669927869233096
LinearRegression >> r2_score: 0.9815426962651943
```

```
LassoCV >> best parameters: {'cv': 20, 'n_alphas': 150}
LassoCV >> best score: -0.007781821487029114
LassoCV >> RMSE: 0.06438289041458628
LassoCV >> MAE: 0.05034782072248121
LassoCV >> r2_score: 0.9787863340316797
```

```
Ridge >> best parameters: {'alpha': 0.1}
Ridge >> best score: -0.008957631004919748
```

3-1-4- التحقق من صحة الاستنتاجات :

يمكن التحقق من صحة الاستنتاجات باستخدام الاجرائية ModelComparePredictAndReal، حيث تقوم هذه الاجرائية بالمقارنة بين القيمة المتوقعة باستخدام خوارزمية معينة و القيمة الحقيقية للخروج (نوع المادة).
عمل الاجرائية: تقوم الاجرائية باستخدام خوارزمية التنبؤ Model وتدريبها على بيانات التدريب x_train,y_train واختبار دقة التنبؤ على بيانات الاختبار x_test, y_test .
خرج الاجرائية: خرج نصي يظهر النتيجة score على بيانات التدريب والاختبار، كما تظهر الخرج الاختباري المتوقع من قبل الاجرائية والخرج الاختباري الحقيقي.
من خلال تنفيذ الاجرائية السابقة على 4 خوارزميات ينتج لدينا مايلي:

```
DecisionTreeRegressor(criterion='mse',
max_depth=3, max_features=None,
max_leaf_nodes=5,
min_impurity_decrease=0.0,
min_impurity_split=None,
min_samples_leaf=1,
min_samples_split=2,
min_weight_fraction_leaf=0.0,
presort=False, random_state=None,
splitter='best')
Model Train Score is : 1.0
Model Test Score is : 1.0
Predicted Value for Model is : [1. 1. 0. 1. 0.]
Real Value for Model is : [1 1 0 1 0]
-----
RandomForestRegressor(bootstrap=False,
criterion='mse', max_depth=None,
max_features='auto',
max_leaf_nodes=None,
min_impurity_decrease=0.0,
min_impurity_split=None,
min_samples_leaf=1,
min_samples_split=2,
min_weight_fraction_leaf=0.0,
n_estimators=10, n_jobs=None,
```

2-1-4- الاستنتاجات:

من خلال التدقيق على قيمة r2_score (التي يجب أن تكون في أحسن حالاتها تساوي 1)، وقيمة RMSE,MEA (التي يجب أن تكون في أحسن حالاتها تساوي 0) يمكن استنتاج مايلي:

1- أن الخوارزمية DecisionTreeRegressor مع العوامل
{'criterion': 'mse', 'max_depth': 3, 'max_features': None, 'max_leaf_nodes': None, 'min_samples_leaf': 1, 'min_samples_split': 2, 'min_weight_fraction_leaf': 0, 'random_state': None, 'splitter': 'best'}
(RMSE= 0.0, MAE= 0.0, r2_score= 1.0) أي أن

القيم المتوقعة لتحديد نوع المادة مطابق تماماً للواقع.

2- أن الخوارزمية RandomForestRegressor مع العوامل
{'bootstrap': False, 'max_features': 'auto', 'n_estimators': 10}
نتيجة مثالية تماماً (RMSE= 0.0, MAE= 0.0, r2_score= 1.0)، أي أن القيم المتوقعة لتحديد نوع المادة مطابق تماماً للواقع.

3- الخوارزميات Ridge (r2_score=0.98), LinearRegression(r2_score=0.98), SVR(r2_score=0.95), LassoCV(r2_score=0.97), Lasso(r2_score=0.93) تعطي نتائج قريبة جداً من الواقع.

4- الخوارزمية KNeighborsRegressor (r2_score= -1.8) تعطي نتائج بعيدة عن الواقع.

5- هذه النتائج المثالية ناتجة عن قلة البيانات (50 عينة) من ناحية، ووجود نوعي مادة فقط للتنبؤ (material=ABS or PLA)

دراسة استخدام خوارزميات تعليم الآلة للتنبؤ بالجودة....

```
oob_score=False, random_state=None,
verbose=0, warm_start=False)
Model Train Score is : 1.0
Model Test Score is : 1.0
Predicted Value for Model is : [1. 1. 0. 1. 0.]
Real Value for Model is : [1 1 0 1 0]
```

```
-----
LassoCV(alphas=None, copy_X=True, cv=20,
eps=0.001, fit_intercept=True,
max_iter=1000, n_alphas=150, n_jobs=None,
normalize=False,
positive=False, precompute='auto',
random_state=None,
selection='cyclic', tol=0.0001, verbose=False)
Model Train Score is : 0.9815730355601424
Model Test Score is : 0.9526320378092709
Predicted Value for Model is : [ 0.92731498
0.89257066 -0.05076183 0.99471208
0.19342351]
Real Value for Model is : [1 1 0 1 0]
```

```
-----
KNeighborsRegressor(algorithm='auto',
leaf_size=30, metric='minkowski',
metric_params=None, n_jobs=None,
n_neighbors=5, p=2,
weights='distance')
Model Train Score is : 1.0
Model Test Score is : 0.5785761269631022
Predicted Value for Model is : [0.59353472
0.8103651 0.36717229 0.58803187 0. ]
Real Value for Model is : [1 1 0 1 0]
```

من خلال تنفيذ الخوارزميات السابقة على 5 عينات عشوائية
من أصل 50 عينة متوفرة، واستخدام باقي العينات (45
عينة) لتدريب الخوارزميات يمكن ملاحظة مايلي:

بركات و جنيدي

- DecisionTreeRegressor,
RandomForestRegressor: ينتج عنها تطابق كامل بين
القيم الحقيقية والقيم المتوقعة.
- LassoCV: ينتج عنها تطابق تقريبي بين القيم
الحقيقية والقيم المتوقعة.
- KNeighborsRegressor: ينتج عنها قيم
متوقعة بعيدة عن القيم الحقيقية.

2-4-التنبؤ بجودة المنتج اعتماداً على بارامترات الدخل:

يمكن أن نحدد مصفوفة الدخل وهي عبارة عن 11 عمود
تساعد في التنبؤ بجودة المنتج، وهذا البارامترات هي:
'layer_height', 'wall_thickness', 'infill_density',
'nozzle_temperature', 'bed_temperature',
'print_speed', 'fan_speed', 'roughness', 'elongation',
'infill_pattern_grid', 'infill_pattern_honeycomb',
'material_abs', 'material_pla'

بينما يمكن اعتبار الخرج الذي يجب التنبؤ به هو العمود
tensile_strength .

1-2-4-استعراض النتائج:

تم استخدام الاجرائية السابقة modelTest2 لاختبار
الخوارزميات التالية: RandomForestRegression, SVR,
LinearRegression, Ridge, Lasso, LassoCV,
KNeighborsRegressor, DecisionTreeRegressor,
وكانت النتائج كما في الأشكال (2,3,4,5):


```

model=SVR
params_grid={'C':[0.1,1,10,50,100],
            'gamma':[1,0.1,0.01,0.001],
            'kernel':['rbf']}
modelName="SVR"
modelTest2(modelName,model,params_grid,x_1,y_1)

SVR >> best parameters: {'C': 50, 'gamma': 0.01, 'kernel': 'rbf'}
SVR >> best score: -88.9873260834987
SVR >> RMSE: 9.174468526204903
SVR >> MAE: 8.50002767920193
SVR >> r2_score: -12093875855.421436

```

```

model = RandomForestRegressor
params_grid = {
    "n_estimators"      : [10,20,30],
    "max_features"      : ["auto", "sqrt", "log2"],
    "min_samples_split" : [2,4,8],
    "bootstrap"         : [True, False],
}
modelName="RandomForestRegressor"
modelTest2(modelName,model,params_grid,x_1,y_1)

RandomForestRegressor >> best parameters: {'bootstrap': True, 'max_features': 'auto', 'min_samples_split': 2, 'n_estimators': 20}
RandomForestRegressor >> best score: -21.353099999999998
RandomForestRegressor >> RMSE: 4.603694168817038
RandomForestRegressor >> MAE: 3.59
RandomForestRegressor >> r2_score: 0.5682975516356379

```

الشكل (2): نتائج اختبار SVR,RandomForestRegressor

```

from sklearn.linear_model import LinearRegression
model=LinearRegression
modelName="LinearRegression"
params_grid = {'fit_intercept':[True,False], 'normalize':[True,False], 'copy_X':[True, False]}
modelTest2(modelName,model,params_grid,x_1,y_1)

LinearRegression >> best parameters: {'copy_X': True, 'fit_intercept': True, 'normalize': False}
LinearRegression >> best score: -47.18243904841822
LinearRegression >> RMSE: 4.391234363967359
LinearRegression >> MAE: 3.7550961410123804
LinearRegression >> r2_score: 0.7298522148183642

```

```

from sklearn.linear_model import Ridge
model=Ridge
modelName="Ridge"
params_grid = {'alpha':[0.1,1,10,20,50,90,150,180,200]}
modelTest2(modelName,model,params_grid,x_1,y_1)

Ridge >> best parameters: {'alpha': 0.1}
Ridge >> best score: -45.479119489953334
Ridge >> RMSE: 4.4330955324502215
Ridge >> MAE: 3.81147920011649
Ridge >> r2_score: 0.7219307839721173

```

الشكل (34): نتائج اختبار LinearRegression,Ridge

```

from sklearn.linear_model import Lasso
model=Lasso
modelName="Lasso"
params_grid = {'alpha':[0.02, 0.024, 0.025, 0.026, 0.03,0.4,0.6,0.8,1]}
modelTest2(modelName,model,params_grid,x_1,y_1)

Lasso >> best parameters: {'alpha': 0.03}
Lasso >> best score: -44.180360477299665
Lasso >> RMSE: 4.480491781794881
Lasso >> MAE: 3.7381263228342503
Lasso >> r2_score: 0.7182761020896247

```

```

from sklearn.linear_model import LassoCV
model=LassoCV
modelName="LassoCV"
params_grid = {'cv' : [5,10,15,20], 'n_alphas' : [100,150,200,250,300]}
modelTest2(modelName,model,params_grid,x_1,y_1)

LassoCV >> best parameters: {'cv': 5, 'n_alphas': 100}
LassoCV >> best score: -44.288092470397316
LassoCV >> RMSE: 4.588468580131184
LassoCV >> MAE: 3.830122296170141
LassoCV >> r2_score: 0.6874849718396701

```

الشكل (4): نتائج اختبار Lasso,LassoCV

```

from sklearn.neighbors import KNeighborsRegressor
model=KNeighborsRegressor
modelName="KNeighborsRegressor"
params_grid = {'n_neighbors': range(1, 12, 2), 'weights': ['uniform', 'distance'],}
modelTest2(modelName,model,params_grid,x_1,y_1)

KNeighborsRegressor >> best parameters: {'n_neighbors': 11, 'weights': 'uniform'}
KNeighborsRegressor >> best score: -110.26264462809918
KNeighborsRegressor >> RMSE: 9.634390878685887
KNeighborsRegressor >> MAE: 8.854545454545454
KNeighborsRegressor >> r2_score: -16.03559890184896

```

```

from sklearn.tree import DecisionTreeRegressor
model=DecisionTreeRegressor
modelName="DecisionTreeRegressor"
params_grid = {"splitter": ["best", "random"],
               "max_depth": [1,3,5,7],
               "min_samples_leaf": [1,2,},
               "min_weight_fraction_leaf": [0.1,0.2,0.3],
               "max_features": ["auto", "log2", "sqrt", None],
               "max_leaf_nodes": [None, 10, 20] }
modelTest2(modelName,model,params_grid,x_1,y_1)

DecisionTreeRegressor >> best parameters: {'max_depth': 3, 'max_features': 'auto', 'max_leaf_nodes': 10, 'min_samples_leaf': 1, 'min_weight_fraction_leaf': 0.1, 'splitter': 'best'}
DecisionTreeRegressor >> best score: -24.833716666666664
DecisionTreeRegressor >> RMSE: 5.488704542150216
DecisionTreeRegressor >> MAE: 4.171428571428573
DecisionTreeRegressor >> r2_score: 0.313080639063841

```

الشكل (54): نتائج اختبار KNeighborsRegressor, DecisionTreeRegressor

3-2-4- الاستنتاجات:

1- يمكن اعتبار $r_2_score=0.7$ للخوارزميات LinearRegression, Ridge, Lasso جيدة جداً مع هذا العدد من العينات (50 عينة)، وبالتالي يمكن استخدام هذه الخوارزميات للتنبؤ مع بيانات التصنيع التجميعي.

2- يمكن استخدام الخوارزميات Lasso, LassoCV, RandomForestRegressor, DecisionTreeRegressor للتنبؤ مع بيانات التصنيع التجميعي ولكن بدقة أقل من الخوارزميات المذكورة في البند 1

3- لا يمكن استخدام SVR, KNeighborsRegressor أبداً مع هذا النوع من البيانات.

4- إن ازدياد عدد العينات يحسن من دقة النتائج، وهنا يجب اعتبار أن استخدام هذه الخوارزميات يجب أن يتم مع عدد عينات كبير يزيد على 1000 عينة.

4-2-4- التحقق من الاستنتاجات:

للتحقق من أن الاستنتاجات السابقة صحيحة يمكن إجراء اختبار حقيقي لدقة الخوارزميات LinearRegression, Ridge كأفضل نتائج، واختبار

2-2-4- تصنيف الخوارزميات: من خلال التدقيق على نتيجة r_2_score ، فإن ترتيب الخوارزميات التي يمكن استخدامها من الأفضل إلى الأسوأ هي:

1- LinearRegression: قيمة $r_2_score=0.73$ مع البارامترات التالية { 'copy_X': True, 'fit_intercept': True, 'normalize': False }

2- Ridge: قيمة $r_2_score=0.721$ مع البارامترات التالية { 'alpha': 0.1 }

3- Lasso: قيمة $r_2_score=0.718$ مع البارامترات التالية { 'alpha': 0.03 }

4- LassoCV: حيث قيمة $r_2_score=0.687$ مع البارامترات التالية { 'cv': 5, 'n_alpha': 0.03 }

5- RandomForestRegression: قيمة $r_2_score=0.56$

6- DecisionTreeRegressor: قيمة $r_2_score=0.31$

7- KNeighborsRegressor, SVR: قيمة r_2_score سالبة .

دراسة استخدام خوارزميات تعليم الآلة للتنبؤ بالجودة....

KNeighborsRegressor,SVR كأسوأ نتائج، وذلك من

خلال الاجرائية testModelScatterPlot .

عمل الاجرائية: تقوم هذه الاجرائية بتدريب خوارزمية التنبؤ

التي يتم تمريرها للاجرائية من خلال بيانات التدريب ومن ثم

يتم اختبار عمل الاجرائية على بيانات الاختبار واطهار

نتائج المقارنة بين القيم المتوقعة والقيم الحقيقية. في

الاجرائية تم اعتبار tension_strength هو الخرج الذي

سيتم دراسته.

دخل الاجرائية:

Model: خوارزمية التنبؤ مع العوامل الخاصة فيها.

X_train: مصفوفة بيانات التدريب للدخل.

Y_train: بيانات التدريب للخرج.

X_test: مصفوفة بيانات الاختبار للدخل.

Y_test: بيانات الاختبار للخرج.

خرج الاجرائية:

خرج نصي على شكل جدول يظهر مقارنة بين القيم

الحقيقية y_test = real_tension_strength

بركات و جنيدي

والقيم التي تم التنبؤ بها predict(x_test) =

،predicted_tension_strength

بالإضافة إلى خرج على شكل مخطط يظهر الفرق بين

القيمتين السابقتين.

في البداية يتم تقسيم البيانات الى بيانات تعليم (40 عينة)

وبيانات اختبار (10 عينة) ثم يتم تنفيذ الاجرائية على 4

خوارزميات هـ

LinearRegression,Ridge,KNeighborsRegresso

:r,SVR

1-نلاحظ من الشكلين 6 و 7 أن القيم المتوقعة (النقاط

الحمراء) قريبة من القيم الحقيقية (النقاط الزرقاء) كما يوجد

بعض النقاط التي يمكن اعتبارها شاذة عن النتائج المتوقعة


(يمكن أن يكون السبب هو قلة البيانات).

2-نلاحظ من الشكلين 8 و 9 أن القيم المتوقعة (النقاط

الحمراء) بعيدة عن القيم الحقيقية (النقاط الزرقاء) وهذا يؤكد

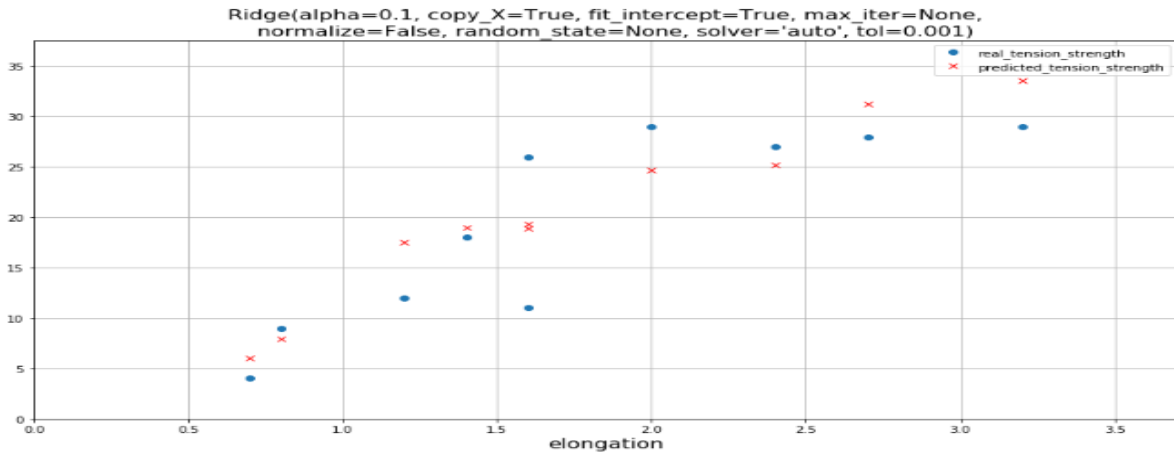
عدم امكانية استخدام KNeighborsRegressor ,SVR

لهذا النوع من البيانات.



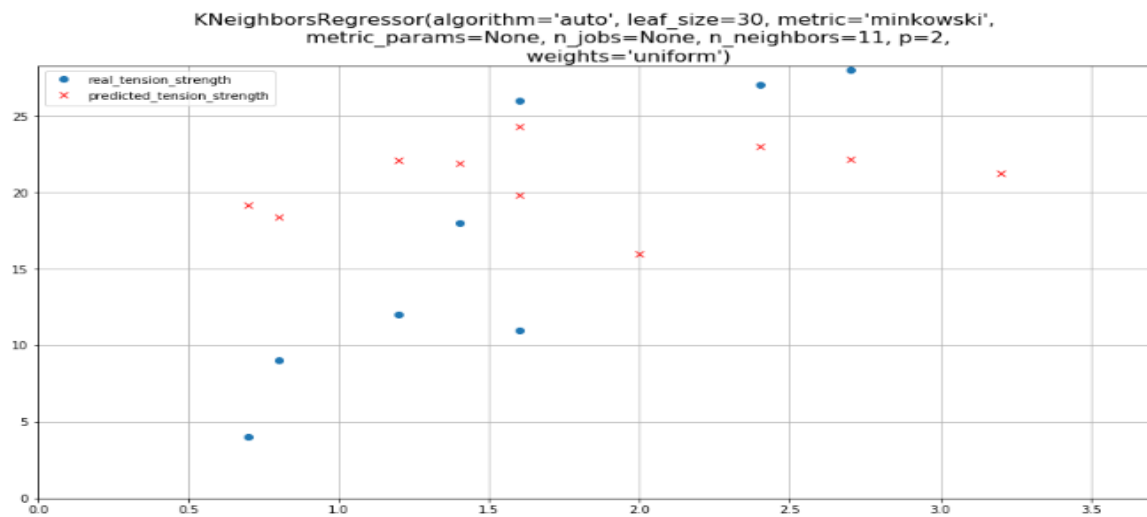
الشكل (6): مقارنة بين القيم الحقيقية والمتوقعة للخوارزمية LinearRegression

```
Ridge(alpha=0.1, copy_X=True, fit_intercept=True, max_iter=None,
normalize=False, random_state=None, solver='auto', tol=0.001)
elongation real_tension_strength predicted_tension_strength
0 0.8 9 7.936500
1 0.7 4 6.059175
2 2.4 27 25.233001
3 2.7 28 31.255976
4 1.6 26 19.339375
5 3.2 29 33.548184
6 1.2 12 17.546298
7 1.6 11 18.856438
8 1.4 18 19.014227
9 2.0 29 24.656630
```



الشكل (6): مقارنة بين القيم الحقيقية والمتوقعة للخوارزمية Ridge

```
KNeighborsRegressor(algorithm='auto', leaf_size=30, metric='minkowski',
metric_params=None, n_jobs=None, n_neighbors=11, p=2,
weights='uniform')
elongation real_tension_strength predicted_tension_strength
0 0.8 9 18.363636
1 0.7 4 19.181818
2 2.4 27 23.000000
3 2.7 28 22.181818
4 1.6 26 19.818182
5 3.2 29 21.272727
6 1.2 12 22.090909
7 1.6 11 24.272727
8 1.4 18 21.909091
9 2.0 29 16.000000
```

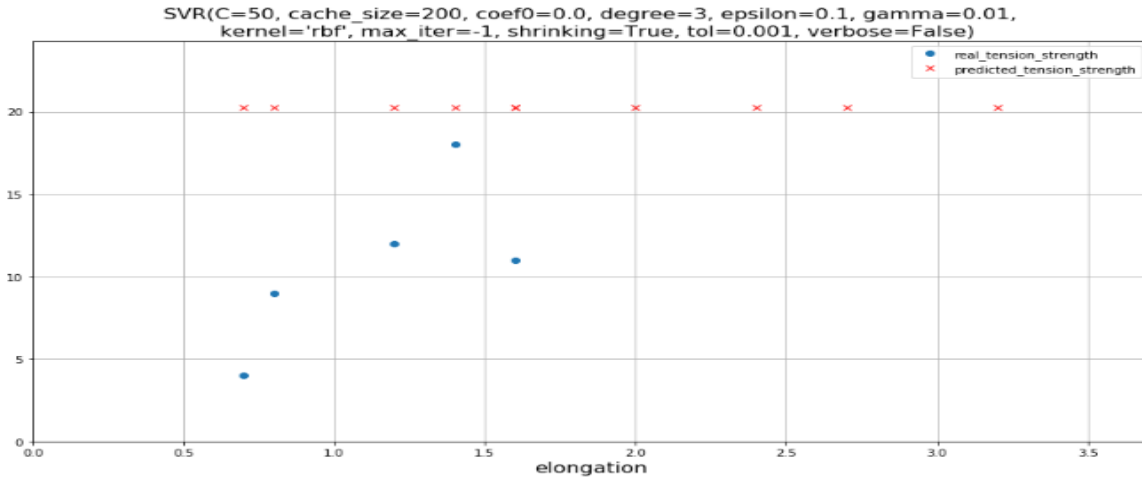


الشكل (7): مقارنة بين القيم الحقيقية والمتوقعة للخوارزمية KNeighborsRegressor

دراسة استخدام خوارزميات تعليم الآلة للتنبؤ بالجودة....

بركات و جنيدي

```
SVR(C=50, cache_size=200, coef0=0.0, degree=3, epsilon=0.1, gamma=0.01,  
kernel='rbf', max_iter=-1, shrinking=True, tol=0.001, verbose=False)  
elongation real_tension_strength predicted_tension_strength  
0 0.8 9 20.280081  
1 0.7 4 20.280081  
2 2.4 27 20.280082  
3 2.7 28 20.280081  
4 1.6 26 20.279803  
5 3.2 29 20.280081  
6 1.2 12 20.280079  
7 1.6 11 20.280081  
8 1.4 18 20.280083  
9 2.0 29 20.280081
```



الشكل(8): مقارنة بين القيم الحقيقية والمتوقعة للخوارزمية S

التمويل: هذا البحث ممول من جامعة دمشق وفق رقم التمويل (501100020595).

References –5

- [1] S. Dufera, "ADDITIVE MANUFACTURING TECHNOLOGIES," International Journal of Management, Information Technology and Engineering, vol. 4, no. 7, 2019.
- [2] G. Shobha and S. Rangaswamy, "Chapter 8 - Machine Learning," *Handbook of Statistics*, vol. 38, pp. 197-228, 2018.
- [3] H. K. Dave, A. R. Prajapati, S. R. Rajpurohit, N. H. Patadiya and H. K. Raval, "Investigation on tensile strength and failure modes of FDMprinted part using in-house fabricated PLA filament," *Advances in Materials and Processing Technologies*, 2020.
- [4] M. S. Chaudhry and A. Czekanski, "Evaluating FDM Process Parameter Sensitive Mechanical Performance of Elastomers at Various Strain Rates of Loading," *Materials*, 2020.
- [5] Z. Abdullah, H. Ting, M. Ali, M. Fauadi, M. Kasim, A. Hambali, M. M. Ghazaly and F. Handoko, "THE EFFECT OF LAYER THICKNESS AND RASTER ANGLES ON TENSILE STRENGTH AND FLEXURAL STRENGTH FOR FUSED DEPOSITION MODELING (FDM) PARTS," *JOURNAL OF ADVANCED MANUFACTURING TECHNOLOGY (JAMT)*, vol. 12, 2018.
- [6] S. R. Rajpurohit and H. K. Dave, "Impact of Process Parameters on Tensile Strength of Fused Deposition Modeling Printed Crisscross Polylactic Acid," *International Journal of Materials and Metallurgical Engineering*, vol. 12, 2018.
- [7] H. Li, T. Wang and Z. Yu, "The Quantitative Research of Interaction between Key Parameters and the Effects on Mechanical Property in FDM," *Advances in Materials Science and Engineering*, 2017.
- [8] C. K. Basavaraj and M. Vishwas, "Studies on Effect of Fused Deposition Modelling Process Parameters on Ultimate Tensile Strength and Dimensional Accuracy of Nylon," *Materials Science and Engineering*, vol. 149, 2016.
- [9] S. Deshwal, A. Kumar and D. Chhabra, "Exercising hybrid statistical tools GA-RSM, GA-ANN and GA-ANFIS to optimize FDM process parameters for tensile strength improvement," *CIRP Journal of Manufacturing Science and Technology*, vol. 31, pp. 189-199, 2020.
- [10] M. Hikmat, S. Rostam and Y. M. Ahmed, "Investigation of tensile property-based Taguchi method of PLA parts fabricated by FDM 3D printing technology," *Results in Engineering*, vol. 11, 2021.
- [11] T. Hou, T. Huang, F. Sun and S. Wang, "Ultimate Tensile Strength in Fused Deposition Modeling Considering Process Parameters of Flow Rate and Printing Head Speed," in *12th International Conference on Reliability, Maintainability, and Safety (ICRMS)*, 2018.
- [12] "2 K-nearest Neighbours Regression," [Online]. Available: https://bookdown.org/tpinto_home/Regression-and-Classification/k-nearest-neighbours-regression.html.
- [13] C. Bakshi, "Random Forest Regression," 2020. [Online]. Available: <https://levelup.gitconnected.com/random-forest-regression-209c0f354c84>.

- [14] K. ZIMENKO, "FDM_LinearAdvance," 1 1 2022. [Online]. Available: <https://www.kaggle.com/datasets/kseniiazimenko/fdm-linearadvance>.
- [15] <https://vijay-choubey.medium.com/>, "how-to-evaluate-the-performance-of-a-machine-learning-model," [Online]. Available: <https://vijay-choubey.medium.com/how-to-evaluate-the-performance-of-a-machine-learning-model-d12ce920c365>.