

Prediction of Wheat Yield in Baghdad Governorate Using Intelligence Support Vector Machine Algorithm

Marwah Farooq Faeq*

Department of Agricultural Economics, College of
Agriculture Engineering Sciences, University of
Baghdad

marwa.faeq2208p@coagri.uobaghdad.edu.iq

Received: 19/11/2025

Prof. Dr. Eskander Hussein Ali

Department of Agricultural Economics, College of
Agriculture Engineering Sciences, University of
Baghdad

eskander.hussein@coagri.uobaghdad.edu.iq

Accepted: 28/12/2025

Published: 31/3/2026

Abstract:

This research aimed to analyze the effect of economic, social, technical, administrative, and climatic factors on the prediction of productivity for wheat during the 2023-2024 growing season for (100) farmers were randomly surveyed in Baghdad Governorate using an intelligent machine learning algorithm (Support Vector Machine SVM), and its performance was evaluated using R^2 and RMSE criteria. Results showed that the relative importance of the hail and educational level variables (HAIL and EDU) reached 43.20% and 39.70%, respectively. Therefore, we conclude that these two variables accounted for a combined percentage exceeding 80%, thus achieving the first and second ranks and demonstrating statistical significance (Sig.) at a significance level of ($P < 0.01$), This indicates that they were the most influential factors on the dependent variable (PRODUC) Among the other independent variables. We concluded that the SVM model had acceptable fit of Goodness, reliability, and good prediction accuracy, as the results of the performance evaluation criteria represented by (R^2 , RMSE) reached approximately (0.66, 23.89 kg/dunum), so research hypothesis was proven. The research recommends the necessity of resorting to the use of the SVM machine learning algorithm in predicting the productivity of other crops for different agricultural sites.

Key words: Artificial Intelligence, Machine Learning, SVM, Hail, Risk Management.

توقع إنتاجية محصول القمح في محافظة بغداد باستخدام خوارزمية آلة الدعم الناقل الذكية

أ.د. إسكندر حسين علي

مروه فاروق فائق

قسم الاقتصاد الزراعي، كلية علوم الهندسة الزراعية، جامعة بغداد

قسم الاقتصاد الزراعي، كلية علوم الهندسة الزراعية، جامعة بغداد

المستخلص:

هدف البحث الى تحليل أثر العوامل الاقتصادية والاجتماعية والفنية والإدارية والمناخية في توقع إنتاجية محصول القمح الموسم الزراعي (٢٠٢٣-٢٠٢٤) لـ (١٠٠) مزارع في محافظة بغداد تم استبيانهم عشوائياً باستخدام خوارزمية التعلم الآلي الذكية (آلة الدعم الناقل SVM) فضلاً عن تقييم أداءها باستخدام معياري (R^2 , RMSE)، بينت النتائج ان الأهمية النسبية لمتغيري البرد والمستوى التعليمي (HAIL، EDU) بلغت (٤٣.٢٠، ٣٩.٧٠) % على التوالي عليه نستنتج ان المتغيرين سجلا لوجودهما مجموع نسب تجاوز الـ 80% فحصلنا على الرتبتين الأولى والثانية واطهرا دلالتهم الإحصائية (Sig.) عند مستوى معنوية ($0.01 < P$) بذلك يتضح انهم الأكثر تأثيراً في المتغير التابع (PRODUC) من بين المتغيرات المستقلة الأخرى، كما استنتج البحث جودة توفيق مقبولة وموثوقية ودقة توقع جيدة لأنموذج SVM إذ بلغت نتائج معايير التقييم الأداء المتمثلة بـ (R^2 , RMSE) نحو (٠.٦٦، ٢٣.٨٩ كغم/دونم) بذلك تم اثبات فرضية البحث، يوصي البحث بضرورة اللجوء الى استخدام خوارزمية التعلم الآلي SVM في توقع إنتاجية محاصيل أخرى لمواقع زراعية مختلفة.

الكلمات المفتاحية: الذكاء الاصطناعي، تعلم الآلي، SVM، برد، إدارة مخاطر.

المقدمة

تعد الزراعة إحدى الدعائم الأساسية لاقتصاد أي دولة في العالم وتحديدًا النامية منها العراق، فاستنزاف المدخلات الانتاجية وارتفاع كلفتها وقلة الأيدي العاملة، كذلك المخاطر التي تواجهها من التغيرات المناخية والتقلبات الاقتصادية، فضلاً عن الزيادة

المُضطربة في اعداد سكان العالم الى اكثر من احدى عشر مليار نسمة بحلول عام ٢٠٥٠ (FAO, 2024) التي تتطلب زيادة في الانتاج العالمي من الغذاء بنسبة ٧٠ % لتتناسب طردياً مع الطلب المتزايد عليه لـ (٢.٣) مليار نسمة اضافية، هذا يلزم الدول النامية زيادة انتاجها الى الضعف (FAO, 2009)، من خلال تكثيف الانتاج الزراعي الحالي بما مُتاح من الاراضي الزراعية ولكن هذا التكثيف سيُشكل ضغطاً كبيراً على الوقود الأحفوري والذي من المتوقع ان يكون عرضه غير كافٍ لمواجهة الطلب عليه خلال (٢٠١٥-٢٠) سنة القادمة دون اتخاذ التدابير الجذرية والاستثمارات اللازمة في جميع انحاء العالم (Schindler & Zittel, 2008)، لذلك بدأت السياسات الزراعية بالتغير والاهتمام بمجال التكنولوجيا، فأخذت تطبيقات الذكاء الاصطناعي (Artificial Intelligence) دوراً مهماً كأحد الحلول الأكثر قابلية للتطبيق لغرض معالجة نقص الغذاء والتكيف مع احتياجات العدد المتزايد من السكان (Zha, 2020)، عليه تم استخدام في بحثنا هذا احدى تطبيقات الـ AI التحليلية الـ وهي خوارزمية التعلم الالي الذكية (الـ SVM الناقل) لتوقع إنتاجية احد أهم محاصيل الحبوب الاستراتيجية في العراق (القمح) لعينة من مزارعي محافظة بغداد الموسم الزراعي (٢٠٢٣-٢٠٢٤)، حيث يُعد القمح من أهم محاصيل الحبوب الرئيسة التي تسهم في تعزيز الامن الغذائي لسكان العراق بحكم أهميته الغذائية لاحتوائه على الكربوهيدرات والبروتينات والمعادن فهو غذاءً شائعاً بين المستهلكين فضلاً عن أهميته الاقتصادية ودوره الأساس في التنمية (Mohammed and Kadhim, 2024)، (Baqir and Zeboon, 2024)، (Al-Maarouf and Saed, 2023)، (جبارة ونغمش، ٢٠٢٢)، فمحصول القمح يُزرع في اغلب محافظات العراق الشمالية والوسطى والجنوبية ونجاح زراعته يعتمد على الإدارة المثلى ذات التكنولوجيا الحديثة (Abdulla et al., 2024)، لزيادة الإنتاجية بالتالي الإنتاج لتلبية الطلب المتزايد عليه من قبل سكان العراق (Rwaida and Hama-Amin, 2024)، ونشير الى ان انتاج العراق للموسم المذكور عدا إقليم كردستان بلغ نحو (5234) الف طن بمتوسط إنتاجية (٧٩٦) كغم/ دونم، في حين بلغ انتاج محافظة بغداد (٣٠) الف طن وبأهمية نسبية قدرت بـ ٠.٥٨ % من اجمالي كمية الإنتاج على مستوى العراق وبمتوسط إنتاجية (٨٦٦) كغم/ دونم.

١- منهجية البحث وبعض الدراسات السابقة

١-١ منهجية البحث Methodology of Research

١-١-١ مشكلة البحث: Research Problem

١-١-١-١ هل ان استخدام خوارزمية آلة الدعم الناقل الذكية SVM سيسهم في بناء انموذج دقيق لتوقع إنتاجية محصول القمح في محافظة بغداد ويفسر العلاقة غير الخطية بين العوامل (الاقتصادية والاجتماعية والفنية والإدارية والمناخية) وإنتاجية القمح لدعم القرارات الزراعية.

١-١-١-٢ عدم كفاية الطرائق التحليلية التقليدية المتبعة من قبل صنّاع القرار لرسم السياسات الزراعية ووضع الخطط الاستراتيجية المستقبلية بضمنها توقع الإنتاجية.

٢-١-١ أهمية البحث: Research Importance

١-٢-١-١ ملئ الفجوة البحثية لقلّة الدراسات والبحوث المحلية التي تبحث في هذا المجال، كما يقدم إطاراً قياسياً يمكن استخدامه في التوقع والتنبؤ لمحاصيل مختلفة ولمناطق زراعية أخرى.

١-٢-١-٢ أهمية الفئة المستهدفة (صنّاع القرار) و(مزارعي القمح) فالأول يُسهل له رسم السياسات الزراعية سواء كانت سياسة دعم محصول القمح او سعريه او تسويقية فضلاً عن الخطط الاستراتيجية فالتوقع الدقيق ذو أهمية كبيرة في رسم ووضع تلك الخطط لتحقيق اهداف الامن الغذائي فضلاً عن التكاليف والإيرادات المتوقعة، أما للثاني فيُحدد للمزارعين أيضاً العوائد التقريبية بالتالي الارباح من خلال توقع انتاج القمح بصورة ادق بالمقارنة مع أساليب التحليل التقليدية الكلاسيكية التي تواجه صعوبة في التعامل مع العلاقات الزراعية غير الخطية مع الاخذ بنظر الاعتبار عوامل الإنتاج الأخرى والمدخلات الزراعية.

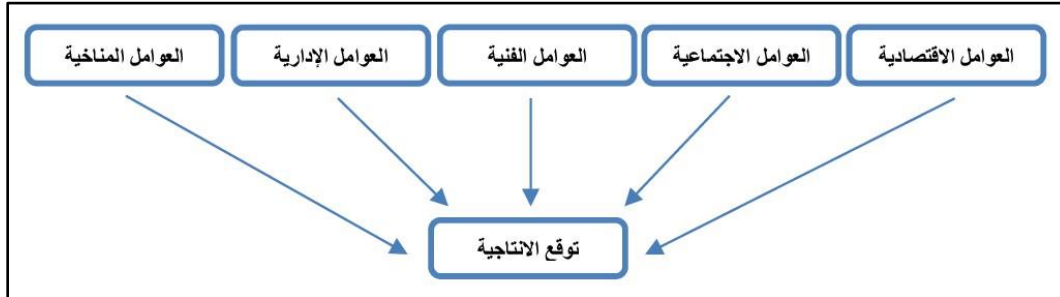
٣-١-١ أهداف البحث: Research Objectives

١-٣-١-١ تحليل أثر العوامل الاقتصادية والاجتماعية والفنية والإدارية والمناخية في توقع إنتاجية محصول القمح باستخدام احدى أدوات الذكاء الاصطناعي المتمثلة بخوارزمية التعلم الالي الذكية آلة الدعم الناقل (Support Vector Machine (SVM).

١-٣-٢-١ تقييم أداء انموذج آلة الدعم الناقل SVM باستخدام معيار معامل التحديد (R^2) ومعيار جذر متوسط الخطأ التربيعي (RSME).

١-١-٤ مخطط البحث الفرضي

شكل (١) مخطط البحث الفرضي



المصدر: اعداد الباحثين.

١-١-٥ فرضيات البحث: Research Hypotheses

يستند البحث الى فرضيتين:

- ١-٥-١-١ ان انموذج SVM يحقق مستوى خطأ في توقع إنتاجية القمح منخفض مقارنةً بالانماذج الخطية التقليدية.
- ١-٥-١-٢ المتغيرات المناخية ذات تأثير أكبر من المتغيرات الاقتصادية والاجتماعية والفنية والإدارية في تذبذب إنتاجية القمح في محافظة بغداد.

١-١-٦ مجتمع وعينة البحث: Research Population and Sample

بلغت عينة البحث (١٠٠) مزارع، شكلت ما نسبته ١.٦٧٪ من مزارعي القمح في محافظة بغداد (مجتمع البحث) البالغ عددهم (٥٩٨٦) مزارع للموسم الزراعي (٢٠٢٣-٢٠٢٤).

١-١-٧ منهج البحث: Research Method

هدف هذا البحث التحليلي الكمي الى دراسة العوامل المؤثرة في توقع إنتاجية محصول القمح لعينة من مزارعي محافظة بغداد باستخدام إحدى أدوات الذكاء الاصطناعي متمثلة بخوارزمية التعلم الآلي (آلة الدعم الناقل) بالاستعانة بلغة البرمجة Python ومن ثم تقييم أداء الانموذج وفق معيارين احصائيين.

١-١-٨ حدود البحث: Research Limitations

١-٨-١-١ الحدود المكانية: (١٨) منطقة زراعية في محافظة بغداد-العراق.

١-٨-١-٢ الحدود الزمانية: الموسم الزراعي (٢٠٢٣-٢٠٢٤) لمحصول القمح.

١-١-٩ وسائل جمع البيانات والمعلومات

تم الحصول على البيانات المقطعية من مصادرها الأولية ميدانياً وفق استبانة وملحقها أعدت لهذا الغرض جُمعت عشوائياً من خلال اجراء المقابلة الشخصية مع المبحوثين (مزارعي القمح) ضمن عينة البحث للموسم الزراعي (٢٠٢٣-٢٠٢٤)، تم تصميم الاستبانة من ثلاث صفحات تضمنت: معلومات عامة عن المزارع، نوع وتكاليف العمليات والمدخلات الزراعية فضلاً عن مواعدي الزراعة والحصاد وكمية الانتاج في حين تضمن الملحق الاستراتيجيات التي يطبقها من عدمه.

١-٢ بعض الدراسات السابقة:

١-٢-١ دراسة (Mhlanga, 2021) سعى فيها الباحث الى دراسة تأثير الذكاء الاصطناعي في تحقيق أهداف التنمية المستدامة تحديداً الهدفين الأول والتاسع، الأول (القضاء على الفقر) والتاسع (الصناعة والابتكار والبنى التحتية)، وتوصل الباحث الى نتائج اهمها ان للذكاء الاصطناعي تأثير قوي في تحقيق الهدفين انفاً وتحسين الموثوقية في البنى التحتية مثل النقل مما يجعل

النمو الاقتصادي والتنمية ممكنة في الاقتصادات الناشئة، كذلك اتضح من هذه الدراسة ان الـ AI يحد من الفقر من خلال تحسين جمع البيانات المتعلقة به من خلال الخرائط، وأوصت الدراسة ان الحكومات تحتاج الى زيادة الاستثمار في الاقتصادات الناشئة الخاصة بالذكاء الاصطناعي مع تقديم الدعم للأبحاث المتعلقة بها لتحقيق اهداف التنمية المستدامة.

١-٢-٢ دراسة (Munnisunker et al., 2022) عن التأثير الذي سيجده الذكاء الاصطناعي في العمل الزراعي في أوروبا، أستند البحث على فرضية مفادها ان الابتكارات التكنولوجية تؤدي دائماً الى تقليل عدد العاملين في القطاع الزراعي والى زيادة كفاءة استخدام المدخلات الزراعية، وقد توصلت النتائج ان المزارعين سيقفون بحاجة الى عمال للعمل جنباً الى جنب مع تقنيات الـ AI، ويعود السبب الى زيادة الاستثمارات في مجال تكنولوجيا الذكاء الاصطناعي وفق البيانات التي تُظهر انخفاض النمو السكاني في أوروبا وصعوبة في حصول المزارعين على أرباح، وبذلك استنتج الباحثين ان نقص العمالة في القطاع الزراعي سيحدث وسوف تكافح الصناعات لسد هذه الفجوة فضلاً عن المهارات المطلوبة للعمل على تلك التقنيات.

١-٢-٣ دراسة (Ashfaq et al., 2024) عن توقع إنتاجية محصول القمح باستخدام ثلاث خوارزميات تعلم آلي (الغابة العشوائية RF، آلة الدعم الناقل SVM، الانحدار باستخدام عامل الانكماش والاختيار بأصغر مطلق "لاسو" LASSO) في مقاطعة بنجاب في باكستان، بالاعتماد على البيانات الزراعية والمناخية والاقمار الصناعية للمدة (٢٠١٧-٢٠٢٢) باستخدام Anaconda Jupyter Notebook و لغة البرمجة Python 3.6 بالاستعانة بحزمة Caret، استنتج البحث تفوق خوارزمية الغابة العشوائية في توقع إنتاجية القمح على خوارزميتي آلة الدعم الناقل وانحدار لاسو إذ بلغت قيم نتائج خوارزمية RF لمعامل التحديد R2 (٠.٨٨) ومتوسط الخطأ المطلق (٠.٥٨) ماوند/ هكتار وجذر متوسط الخطأ التربيعي RMSE (٠.٠٥) ماوند/ هكتار، كما استنتج الباحثين ان دقة خوارزميتي RF و SVM اعلى بالمقارنة مع خوارزمية انحدار LASSO إذ بلغت نسب دقة التوقع (٩٧، ٩٣، ٨٥) % على التوالي.

١-٢-٤ دراسة (Belete, 2025) هدف الباحث الى توقع انتاجية محصول القمح باستخدام خوارزمية الغابة العشوائية (RF) والانحدار الخطي المتعدد الكلاسيكي (MLR) وتقييم أداءهما في أثيوبيا، بينت النتائج ان القيم الحقيقية والمُتوقعة لإنتاجية القمح وفق خوارزمية RF لعام ٢٠١٦ بلغت (٢٦٧٥.٥، ٢٥٩٤.٣٠) كغم/هكتار على التوالي بينما وفق MLR بلغت (٢٦٧٥.٥، ٢١٥٦.٨٣) كغم/هكتار على التوالي، بذلك استنتج الباحث ان القيم المُتوقعة لإنتاجية القمح تتوافق بشكل جيد مع القيم الحقيقية وفق خوارزمية الغابة العشوائية، كذلك اوضحت نتائج معايير تقييم الأداء لانموذجي الغابة العشوائية والانحدار الخطي المتعدد لمتوسط الخطأ المطلق (MAE) نحو (١٣٥.٨٨، ٤٣٥.٧٤) كغم/هكتار على التوالي ولجذر متوسط الخطأ التربيعي (RMSE) البالغة (١٦٣.٩٠، ٦٥٣.٣٩) كغم/هكتار على التوالي، عليه استنتج البحث تفوق خوارزمية الغابة العشوائية على الانحدار الخطي المتعدد في توقع إنتاجية القمح.

١-٢-٥ أهم ما يميز البحث الحالي عن الدراسات السابقة

معظم الأبحاث تفقر الى الجمع ما بين العوامل الاقتصادية والاجتماعية والفنية والإدارية والمناخية معاً وتحليل مدى تأثيرها في توقع إنتاجية محصول القمح، كما أن هنالك ندرة في الدراسات والأبحاث المحلية حول دراسة تحليل توقع الإنتاجية باستخدام إحدى أدوات الذكاء الاصطناعي (خوارزمية التعلم الآلي (آلة الدعم الناقل SVM)).

٢- الجانب النظري

١-٢-١ الذكاء الاصطناعي

تم صياغة مُصطلح الذكاء الاصطناعي (AI) لأول مرة عام ١٩٥٦ في مؤتمر كلية دارتموث Dartmouth College في مدينة Hanover ولاية New Hampshire في الولايات المتحدة الأمريكية، إذ اقترح بروفيسور علوم الرياضيات جون مكارثي John McCarthy في كلية دارتموث اجراء مشروع دارتموث الصيفي للأبحاث عن الذكاء الاصطناعي DSRPAI (McCarthy et al., 2006)، ويُعرف الذكاء الاصطناعي AI بمحاكاة عمليات الذكاء البشري بواسطة الآلات وتحديداً أنظمة الكمبيوتر، وتتضمن هذه العمليات التعلم (اقتناء المعلومات وقواعد استخدامها) كذلك الاستدلال (استخدام القواعد للوصول الى

استنتاجات محددة أو تقريبية) فضلاً عن التصحيح الذاتي (Nayak *et al.*, 2019)، ويُعرف أيضاً الذكاء الاصطناعي هو ذلك البرنامج الذي لن يتعامل أو يتفاعل مع أي شيء أكثر سوءاً من الإنسان في عالم تعسفي مما يعني أن AI عبارة عن مجموعة من البرامج لها مدخلات ومخرجات وموجودة في البيئة (Dobrev, 2012)، وقد أظهرت الدراسات الحديثة ان عدد قليل جداً من الروبوتات التي وصلت إلى نطاق تجاري، ومُعظمها لا يستطيع التنافس مع سرعة نظرائهم من البشر للقيام بأنشطتهم مثال عليها روبوتات إزالة الأعشاب الضارة وروبوتات الحصاد (Shamshiri *et al.*, 2018).

٢-٢ تطبيقات الذكاء الاصطناعي في الزراعة

١-٢-٢ تقنية تكنولوجيا الاستشعار عن بعد Remote Sensing Technology

تُعرف بأنها علم الحصول على المعلومات وتفسيرها من مسافة بعيدة باستخدام أجهزة الاستشعار التي ليس لها اتصال مادي مع الجسم الذي يُجرى رصده (Jensen, 1996)، وتشمل هذه التكنولوجيا RS عمليات الرصد الجوي والأقمار الصناعية للأرض، وتوفر هذه التقنية معلومات مفيدة عن مواقع الكوارث ورسم الخرائط لها فضلاً عن تقييم حالة المحاصيل والتنبؤ بإنتاجيتها وكشف الآفات والأمراض التي تصيبها ويُمكن من خلال RS أن يُتخذ عدد من القرارات على مستوى السياسات الزراعية فيما يخص الأمن الغذائي والتخفيف من حدة الفقر وتحقيق التنمية المستدامة (Liaghat & Balasundram, 2010)، ومن المُحتمل ان تستخدم هذه التقنية كأداة عملية لإداره المحاصيل في مواقع محددة (Casady & Palm, 2002).

٢-٢-٢ الروبوتات الزراعية Agricultural Robotics

أن الروبوت الزراعي يجمع بين التكنولوجيا الزراعية، التكنولوجيا الإلكترونية، تكنولوجيا المعلومات، التكنولوجيا الميكانيكية وتكنولوجيا الذكاء الاصطناعي والتي تعتبر حالياً أحد المحاور الأساسية في بحوث المكننة الزراعية (Van Henten *et al.*, 2009)، تعود دراسة الروبوت الزراعي إلى ثمانينيات القرن الماضي (Cao *et al.*, 1998)، ومن أحد الأمثلة المُبكرة عليها هو حصول الجرارات الزراعية على مدخلات أو بشكل أكثر تحديداً (برنامج يشير إلى مسار التنقل) من نظام تحديد المواقع العالمي GPS (Global Positioning System) وباستخدام رؤية الماكينة يمكن للجهاز (GPS) العمل جنباً إلى جنب مع خط المحاصيل، وبذلك فان تطبيق التكنولوجيا وباستخدام التشغيل الآلي بنسبة (٨٠%) يُقلل العمل اليدوي بنسبة كبيرة، وهذا يُعتبر بمثابة انتقال من أنظمة الزراعة التقليدية إلى أنظمة الزراعة المستقلة تماماً وسيتم اكتساب المزيد من الخبرة من خلال تجربة عناصر الـ Hardware و Software (Bechar & Vigneault, 2016)، وهناك العديد من الروبوتات الزراعية مثال عليها الروبوتات المستخدمة في إزالة الأعشاب الضارة (weed wacker)، وطائرات بدون طيار لرش الأعشاب الضارة والآفات (Ecorobotix Drones) (Ryan *et al.*, 2021).

٣-٢-٢ خوارزمية التعلم الآلي (شجرة القرار) Decision Tree

هي تمثيل بياني لعملية صنع واتخاذ القرار، تعرض فيها الإستراتيجيات وعوائدها (مُخرجاتها) لمساعدة مُتخذ القرار في اختيار القرار الصائب (العامري والغالب، ٢٠٠٨)، تتكون شجرة القرار DT من عُقد وفروع (عقدة القرار، عقدة الحدث، العقدة النهائية، فروع القرار، فروع الاحداث، الاحتمالات، العوائد) (Gedig & Stierner, 2006)، ويتم تقليم الشجرة والتحقق من صحة بيانات السلاسل الزمنية من خلال تقليل تباين الخطأ، يتم استخدام هذه الخوارزمية في التنبؤ بإنتاجية المحاصيل والاسمدة، إذ استخدم (Yadav *et al.*, 2020) عدد من البيانات منها (العوامل المناخية، نسبة النتروجين والفسفور والبوتاسيوم في التربة، المساحة المزروعة، اسم المنطقة المبحوثة) وغيرها، وتمت مقارنة نتائج التحليل لهذه الخوارزمية مع خوارزميات اخرى مثل الانحدار الخطي المتعدد ومتعدد الحدود، وتوصلوا ومن خلال النتائج التي تم الحصول عليها ان افضل تحليل انحدار هو خوارزمية شجرة القرار لتمتعه بدقة واداء اعلى، إذ بلغت نسبة دقته ٨٧% بالمقارنة مع الانحدارين.

٤-٢-٢ خوارزمية التعلم الآلي (آلة الدعم الناقل) Support Vector Machine

تم طرحها لأول مرة من قبل Cortes and Vapnik عام ١٩٩٥ لتصنيف وتحليل البيانات (Abd-Alamir and Hathal, 2024)، فهي منهجية خاضعة للأشراف غير مُعلمية تعتمد على استخدام دوال النواة Kernels لتمثيل بيانات الإدخال في فضاء

يمتاز بسمات عالية الابعاد، فتعمل هذه الدوال على تحويل البيانات من فضاء منخفض الابعاد الى فضاء عالي الابعاد (Ibrahim and Jaber, 2022)، كذلك تعمل على تقليل الأخطاء دون التسبب في فرط التكيف Overfitting حيث يُبنى نموذج الانحدار الخطي لاحقاً، يُسمح بما يُعرف بحيلة النواة Kernel Trick بالنقاط العلاقات غير الخطية بين السمات (المُدخلات او المتغيرات)، بذلك تصبح دالة القرار وفق خوارزمية آلة الدعم الناقل SVM كالاتي (Hayat et al., 2019):

$$f(x) = \sum_{i=1}^N \alpha_i k(x_i, x) + b$$

حيث أن: $f(x)$ دالة آلة الدعم الناقل (المتغير التابع)، N عدد المشاهدات، α_i مضاعف لاجرانج، $k(x_i, x)$ دالة النواة، x_i السمات (المتغيرات المستقلة)، b الحد الثابت (ثابت التقاطع).

٢-٣ اثار استخدام الذكاء الاصطناعي في الزراعة

هنالك آثار عديدة لاستخدام تكنولوجيا الذكاء الاصطناعي في الزراعة (Loudjani et al., 2020) وكما يلي:

- أ. إمكانية الوصول الى جميع المزارعين والتواصل معهم بسهولة عن طريق تطبيقات الهواتف الذكية (AI) لغرض مواكبة البنى التحتية للأرياف بالذكاء الاصطناعي والزراعة الرقمية.
- ب. استخدام الذكاء الاصطناعي يساعد في تقليل تعرض المزارعين خلال عملهم في الاراضي الزراعية للمواد السامة والمبيدات الكيميائية بالتالي حمايتهم من اثارها المُضرة في صحتهم (Rodzalan et al., 2020) فضلاً عن تقليل الحوادث والاضرار الجسدية التي قد يتعرضون لها، إذ ان اغلب الحوادث التي تحدث للمزارعين نتيجة اخطاء بشرية من قبل الأخير بالتعامل مع الماكينة (Vasconez et al., 2019).
- ج. يُحقق الذكاء الاصطناعي أرباح اقتصادية للشركات الزراعية والتكنولوجية وليس للمزارعين ولكن يسمح بحدوث اضرار اجتماعية، اخلاقية، بيئية (Ryan, 2020).
- د. يؤدي الذكاء الاصطناعي الى زيادة رفاهية المزارعين من خلال ازالة العديد من الاعمال الخطرة والمملة التي يقومون بها في الاراضي الزراعية (Ryan, 2022).
- هـ. يعمل الـ AI على خلق وظائف اضافية في قطاعات التكنولوجيا لا سيما البرمجة، كذلك ستسمح تقنيات الذكاء الاصطناعي في تحسين انتاج الغذاء في جميع دول العالم وتقلل حدة الجوع والفقر تحقيقاً لأهداف التنمية المستدامة (Lebid et al., 2023).
- و. يعمل استخدام الذكاء الاصطناعي على زيادة انتاج المحاصيل بموارد إنتاجية اقل وبالتالي تكاليف أقل، كذلك يستطيع الـ AI تغيير طرائق وعمليات انتاج الغذاء ومساعدة القطاع الزراعي في تقليل انبعاثاته من الغازات الدفيئة بنسبة ٢٠٪ (Sahoo & Sharma, 2023).

٣- الجانب العملي

١-٣ تطبيق خوارزمية التعلم الآلي (آلة الدعم الناقل (SVM) Support Vector Machine)

تم تطبيق خوارزمية التعلم الآلي الذكية المتمثلة بآلة الدعم الناقل SVM لتوقع المتغير التابع الكمي إنتاجية القمح PRODUC باستخدام سبع متغيرات مستقلة كمية ونوعية (المستوى التعليمي EDU، الخبرة الزراعية EXPER، حجم العمالة العائلي FAMSIZE، الأسمدة FERT، المبيدات PEST، استراتيجيات إدارة مخاطر التغيرات المناخية STRATEG، البرد HAIL) بالاستعانة باللغة البرمجة Python 3.13، وقد تم احتساب المتغيرين المستقلين النوعيين المستوى التعليمي فأخذ سبع قيم مستمرة (صفر لمستوى دون الابتدائية وهكذا الى مستوى الدراسات العليا بقيمة ستة) بينما متغير البرد اخذ قيمتين هما الصفر والواحد الصحيح (واحد صحيح لتعرض مزارع القمح للبرد مما أدى الى تضرر المحصول وصفر لعدم تعرضها)، اما متغير إدارة استراتيجيات مخاطر التغيرات المناخية تم احتسابه من خلال ملحق استبانة أعد لغرض معرفة الاستراتيجيات التي يطبقها المزارعين من عدمه، صُمم وفق مقياس ليكرت الخماسي (Fifth Likert Scale) مكون من (١٤) استراتيجية.

بذلك تمت صياغة المعادلة الرياضية لأنموذج SVM في بحثنا لتوقع إنتاجية القمح كالآتي:

$$Produc = \sum_{i=1}^{100} \alpha_i k (EDU, EXPER, FAMSIZE, FERT, PEST, STRATEG, HAIL) + b$$

٢-٣ نتائج التحليل لأنموذج SVM

أدناه نتائج تحليل الأهمية النسبية والدلالة الإحصائية للمتغيرات المستقلة لأنموذج SVM الموضحة في الجدول (١):
البرد "الحالوب" Hail: بلغت نسبته ٤٣.٢٠٪ بذلك حصل على (الرتبة الأولى) إذ سجل أعلى أهمية نسبية بين المتغيرات المستقلة الأخرى المؤثرة في المتغير التابع (إنتاجية القمح)، وقد اظهر معنويته (دال احصائياً) عند مستوى ٠.٠٠١، يُعزى السبب لتأثير البرد (الحالوب) بشكل سلبي كبير في إنتاجية الدونم الواحد من القمح تبعاً للمرحلة الفينولوجية للنبات كمرحلة الازهار فالضرر يكون بتكسر السيقان بالتالي تقل عدد السنابل وتتساقط الحبوب، فالبرد يعكس مخاطر التغيرات المناخية السلبية على الإنتاجية بالتالي انخفاض الإنتاج، وهذا ما يؤكد فرضية البحث.

المستوى التعليمي Education Level: بلغت نسبته ٣٩.٧٠٪ بذلك حصل على (الرتبة الثانية) إذ سجل ثاني أعلى أهمية نسبية بين المتغيرات المستقلة الأخرى المؤثرة في المتغير التابع (الإنتاجية)، وقد اظهر معنويته عند مستوى ٠.٠٠١، يُعزى السبب الى أهمية المستوى التعليمي للمزارعين وتأثيره في محصول القمح فيعمل على تحسين اتخاذ القرار في إدارة المزرعة على الرغم من انخفاض المستوى التعليمي لعينة البحث، فالأفراد المتعلمون هم أكثر ميلاً لتطبيق ممارسات او استراتيجيات جديدة للتعامل مع المخاطر الزراعية.

حجم العمالة العائلي Family Labor Size: بلغت نسبته ٨.٤١٪ بذلك حصل على (الرتبة الثالثة)، وقد اظهر معنويته عند مستوى ٠.٠٠٥، يُعزى السبب الى اعتماد المزارعين بشكل كبير على افراد العائلة في تنفيذ العمليات الزراعية تحديداً اصحاب الحيازات الصغيرة السائدين ضمن عينة البحث لانخفاض كلفتهم.

الأسمدة Fertilizers: بلغت نسبته ٤.٧٢٪ بذلك حصل على (الرتبة الرابعة)، وقد اظهر عدم معنويته (غير دال احصائياً)، يُعزى السبب الى عدم التزام مزارعي القمح بالجرعة العلمية والاقتصادية الموصى بها (البديل الثاني) لإضافة سمادي اليوريا والداب كذلك ارتفاع أسعارها وضعف المقدرة المالية للمزارعين ادى الى تقليل الكميات المستخدمة منها.

المبيدات Pesticides: بلغت نسبته ١.٣٩٪ بذلك حصل على (الرتبة الخامسة)، وقد اظهر عدم معنويته، يُعزى السبب لتسجيله هذه الرتبة لوجود متغيرات أخرى أكثر أهمية من المبيدات مؤثرة في الإنتاجية على الرغم من التزام المزارعين برش المبيدات بنوعها (الأوراق العريضة والرفيعة) خلال مراحل نمو القمح حمايةً من الإصابة بالأمراض والآفات.

استراتيجيات إدارة مخاطر التغيرات المناخية Climate Change Risks Management Strategies: بلغت نسبته ١.٣١٪ بذلك حصل على (الرتبة السادسة)، وقد اظهر عدم معنويته، يُعزى السبب لانخفاض المستوى العام لتطبيق مزارعي عينة البحث لأغلب استراتيجيات إدارة مخاطر التغيرات المناخية البالغة (١٤) استراتيجية إذ بلغ متوسط التطبيق (٤١.١٩)، على الرغم من استجابتهم لمخاطر التغيرات المناخية من خلال تلك الاستراتيجيات الأساسية منها التي ساهمت في الحد من التأثير السلبي في إنتاجية القمح، الا ان البعض منها بلغت نسبة التطبيق صفر كالتأمين الزراعي.

الخبرة الزراعية Agricultural Experience: بلغت نسبته ١.٢٨٪ بذلك حصل على (الرتبة الأخيرة "السابعة") إذ سجل أدنى أهمية نسبية بين المتغيرات المستقلة الأخرى المؤثرة في المتغير التابع (الإنتاجية)، وقد اظهر عدم معنويته، يُعزى السبب الى تباين الخبرة بين مزارعي عينة البحث المكتسبة من سنوات العمل الزراعي فضلاً عن عدم تقبل وانخفاض المقدرة المالية للبعض منهم في التحول من أساليب الزراعة التقليدية الى الحديثة.

جدول (١) نتائج تحليل أنموذج SVM

Order	(%) Variable Importance	Sig. or Not Sig	Sig.	Variables
1	43.20	معنوي	0.0036**	HAIL


2	39.70	معنوي	0.0042**	EDU
3	8.41	معنوي	0.0473*	FAMSIZE
4	4.72	غير معنوي	0.169	FERT
5	1.39	غير معنوي	0.490	PEST
6	1.31	غير معنوي	0.871	STRATEG
7	1.28	غير معنوي	0.915	EXPER

المصدر: اعداد الباحثين باستخدام لغة البرمجة Python 3.13.

(**) معنوي عند مستوى 0.001.

(*) معنوي عند مستوى 0.005.

يُعزز الشكل (٢) النتائج المستخلصة من الجدول (١)، إذ يعرض رسماً بيانياً لمخطط شريطي افقي متجمع Clustered Bar يوضح فيه ترتيب المتغيرات المستقلة حسب نسبة تأثيرها في المتغير التابع (إنتاجية القمح) لأنموذج SVM.



شكل (٢) الأهمية النسبية للمتغيرات المستقلة انموذج SVM

المصدر: عمل الباحثين بالاعتماد على بيانات جدول (١) باستخدام برنامج M.S. Excel 21.

٣-٣ تقييم أداء أنموذج SVM

هنالك معيارين لتقييم جودة توفيق كذلك موثوقية ودقة انموذج SVM في توقع إنتاجية القمح كالآتي:

١-٣-٣ معامل التحديد (R²) Coefficient of Determination

بلغت قيمته (0.66) مما يعكس مستوى مقبولاً من جودة توفيق انموذج SVM في توقع قيمة المتغير التابع.

٢-٣-٣ جذر متوسط الخطأ التربيعي (RMSE) Root Mean Squared Error

بلغت قيمته (٢٣.٨٩) كغم/دونم وتشير هذه القيمة الى موثوقية أنموذج SVM الجيدة في توقع قيمة المتغير التابع (إنتاجية القمح)، بل وتدل هذه القيمة المنخفضة على ان الانموذج يمتلك دقة جيدة جداً في التوقع.

٤- الاستنتاجات والتوصيات:

١-٤ الاستنتاجات

أستنتج الباحثين ان كلاً من متغير (HAIL، EDU، FAMSIZE) سجلوا اعلى أهمية نسبية، بذلك يتضح انهم الأكثر تأثيراً في المتغير التابع (إنتاجية القمح PRODUC) من بين المتغيرات المستقلة الأخرى، كما استنتج البحث ان متغيري (EDU، HAIL) سجلا لوحدهما مجموع نسب تجاوز الـ 80% فحصلوا على الرتبين الأولى والثانية، واطهرا دلالتهم الإحصائية (Sig.) عند مستوى معنوية (P < 0.01)، كذلك تم استنتاج ومن خلال نتائج معايير التقييم لجودة توفيق وموثوقية ودقة توقع انموذج SVM المتمثلة بـ

(R^2 , RMSE) التي اشارت الى ان الانموذج ذو مستوى مقبول في توقع قيمة المتغير التابع (الانتاجية) كذلك يتمتع بقدرة تمييزية واضحة في تحديد الأهمية النسبية والدلالة الإحصائية للمتغيرات المستقلة المؤثرة برتب متفاوتة.

٤-٢ التوصيات

يوصي البحث بضرورة اللجوء الى استخدام نماذج الذكاء الاصطناعي المتمثلة بخوارزميات التعلم الآلي Machine Learning Algorithms في توقع إنتاجية المحاصيل الزراعية الأخرى لمواقع مختلفة، كما يوصي باستخدام خوارزميات تعلم الي أخرى كالعابية العشوائية Random Forest (RF) بالاستعانة باللغة البرمجة Python لغرض تحسين جودة توفيق وموثوقية ودقة الانموذج بشكل أفضل وبمستوى اعلى، فضلاً عن وضع استراتيجيات وطنية للزراعة الذكية من قبل أصحاب القرار ورسمي السياسات الزراعية تتضمن دمج تكنولوجيا الذكاء الاصطناعي ضمن الخطط الزراعية مستقبلاً ودعم مشاريع الزراعة الذكية.

References

١. العامري والغالبى، صالح مهدي محسن، طاهر محسن منصور. (٢٠٠٨). الادارة والاعمال. الطبعة الثانية. دار وائل للنشر والتوزيع. رقم الايداع لدى دائرة المكتبة الوطنية: ٢٠٠٦/١١/٢٩٩٣. عمان. الاردن.
٢. جبارة ونغمش، أسامة كاظم، دعاء عباس. (٢٠٢٢). التنبؤ بالقيم المتوقعة لأهم المتغيرات المحددة لمعامل الامن الغذائي لمحصول القمح في العراق حتى عام ٢٠٣٠. مجلة الانبار للعلوم الزراعية. ٢٠ (٢). ص ٤٣٢-٤٥٥.
<https://doi.org/10.32649/ajas.2022.176613>
3. Abd-Alamir, T. H., Hathal, M. S. (2024). Comparative Study of Different Classification Techniques for Pedestrian Detection Application. Journal of Engineering. 30 (8). pp 149-168.
<https://doi.org/10.31026/j.eng.2024.08.10>
4. Abdulla, SH. S., Mustafa, K. M., Sabir, D. A. (2024). Effects of sowing date and locations on the selected wheat cultivars quality performance. Iraqi Journal of Agricultural Sciences 55 (5). pp 1813-1825.
5. Al-Maarouf, E. M., Saed, P. H. (2023). Resistance of Iraqi Wheat cultivars to common bunt disease and molecular diagnosis of the available BT genes in each cultivar. Iraqi Journal of Agricultural Sciences 54 (6). pp 1760-1772.
6. Andrawas, R. J., Hama-Amin, T. N. (2024). The inheritance of some quantitative characters of F2 generation for common wheat in Sulaimani-Iraq. Iraqi Journal of Agricultural Sciences 55 (5). pp 1870-1884.
7. Ashfaq, M, I. Khan, A. Alzahrani, M. U. Tariq, H. Khan and A. Ghani. (2024). Accurate wheat yield prediction using machine learning and climate-NDVI data fusion. IEEE ACCESS, 12, <https://doi.org/10.1109/ACCESS.2024.3376735>
8. Baqir, H. A., Zeboon, N. H. (2024). Response of some characteristics of wheat growth to spraying with vitamin B9 and E. Iraqi Journal of Agricultural Sciences 55 (2). pp 803-812.
9. Bechar, A., Vigneault, C. (٢٠١٦). Agricultural robots for field operations: Concepts and components. Journal of bio systems engineering. 149. pp 94-111. DOI: <https://doi.org/10.1016/j.biosystemseng.2016.06.014>
10. Belete, Y. S., (2025). Wheat Yield Prediction Based on Random Forest Method. Preprints. <https://doi.org/doi:10.20944/preprints202502.1837>
11. Cao, Q.X., Lv, T.S., Nagata, M. (١٩٩٨). Current situation and prospect of robot sorting system for vegetables and fruits in Japan, Mech. Des. Res. 4. pp 9-11.
12. Casady, W.W., Palm, H. L. (٢٠٠٢). Precision agriculture: Remote sensing and ground trothing. Published by MU Extension, University of Missouri-Columbia. pp 6. DOI: <https://extension.missouri.edu/publications/eq453>
13. Dobrev, D. (٢٠١٢). A Definition of Artificial Intelligence, Mathematica Balkanica. New Series. 19. Fasc. 1-2, pp 67-73. DOI: <https://doi.org/10.48550/arXiv.1210.1568>
14. Gedig, M., Stiemer, S. (2006). Decision Tools for the Engineering of Steel Structures. *The Journal of Electronic Structural Engineering*, Department of Civil Engineering. University of British Columbia. 6. pp 19-38.
15. Hayat, U., S. Ali, A. Mateen, and H. Bilal. (2019). The role of agriculture in poverty alleviation: Empirical evidence from Pakistan. Sarhad J. Agricult., vol. 35, no. 4, pp. 1309–1315, 2019.



16. Ibrahim, M. H., Jaber, A. G. (2022). The Use of the Regression Tree and the Support Vector Machine in the Classification of the Iraqi Stock Exchange for the Period 2019-2020. *Journal of Economics and Administrative Sciences* 28 (132). pp 74-87.
17. Jensen, J. R. (١٩٩٦). Remote sensing of the environment: An Earth Resource Perspective. 2nd Ed. Prentice Hall, USA. pp 1-592.
18. Lebid, O.V., Kiporenko, S.S., Vovk, V.Y. (2023). Use of Artificial Intelligence Technologies in Agriculture: European Experience and Application in Ukraine. Vinnitsia National Agrarian University. 45(3). pp 57-71. <https://doi.org/10.15407/emodel.45.03.057>
19. Liaghat, S., Balasundram, S. K. (2010). A Review: The Role of Remote Sensing in Precision Agriculture. *American Journal of Agricultural and Biological Sciences*. 5(١). pp 50-55. <http://dx.doi.org/10.3844/ajabssp.2010.50.55>
20. Loudjani, P., Devos, W., Baruth, B., Lemoine, G. (٢٠٢٠). Artificial Intelligence and EU Agriculture. *JRC* 120221. pp 18-20.
21. Mahmood, M. A., Kadhim, Z. R. (2024). purchase channel selection of agricultural machinery by wheat and barley farmers in Iraq: a transactions cost attitude. *Iraqi Journal of Agricultural Sciences* 55 (2). pp 845-857.
22. McCarthy, J., Minsky, M.L., Rochester N., Shannon, C. E. (٢٠٠٦). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. 31 August, 1955. *AI Magazine*. (٢٧) 4. (©AAAI). pp 12-14. DOI: <https://doi.org/10.1609/aimag.v27i4.1904>
23. Mhlanga, D. (٢٠٢١). Artificial Intelligence in the Industry 4.0 and Its Impact on Poverty, Innovation, Infrastructure Development, and the Sustainable Development Goals: Lessons from Emerging Economies?. *Journal of Sustainability and Industry 4.0 in Civil and Infrastructure Engineering*. MDPI. (١٣) 11. 5788. DOI: <https://www.mdpi.com/2071-1050/13/11/5788>
24. Munnisunker, Sh., Nel, L., Diederichs, D. (٢٠٢٢). The Impact of Artificial Intelligence on Agricultural Labour in Europe. *Journal of Agricultural Informatics*. (١٣) 1. pp 46-54. DOI: <https://doi.org/10.17700/jai.2022.13.1.638>
25. Nayak, A., Loksha, H., Shariff, M. and Khan, M. (٢٠١٩). The Economics of Applications of Artificial Intelligence and Machine Learning in Agriculture. *Int. J. Pure App. Biosci.* (٧) 1. pp 296-305. DOI: <http://dx.doi.org/10.18782/2320-7051.7324>
26. Rodzalan, S.A., Yin, O.G., Noor, N.N.M. (٢٠٢٠). A Foresight study of Artificial Intelligence in the agriculture sector in Malaysia, *International Journal of Advanced Science and Technology*. (٢٩) 6. pp 447-462. DOI: <http://sersec.org/journals/index.php/IJAST/article/view/11469>
27. Ryan, M. (٢٠٢٢). The social and ethical impacts of artificial intelligence in agriculture: mapping the agricultural AI literature. *AI & Society. Journal of Knowledge, Culture and Communication*. 38. pp 2473–2485. DOI: <https://doi.org/10.1007/s00146-021-01377-9>
28. Ryan, M, Van der Burg, S., Bogaardt, M-J. (٢٠٢١). Identifying key ethical debates for autonomous robots in agri-food: a research agenda. *Journal of AI & Ethics*. 2. pp 493-507. DOI: <https://doi.org/10.1007/s43681-021-00104-w>
29. Ryan, M. (٢٠٢٠). Agricultural big data analytics and the ethics of power, *Journal of Agricultural and Environmental Ethics*. 33. pp 49-69. DOI: <https://link.springer.com/article/10.1007/s10806-019-09812-0>
30. Sahoo, P.K., Sharma, D. (2023). Economic impact of artificial intelligence in the field of agriculture. *International journal of horticulture and food science*, 5(1), 29-34. Available from: <https://doi.org/10.33545/26631067.2023.v5.i1a.152>
31. Schindler, K. J., Zittel, W. (٢٠٠٨). Crude Oil – The Supply Outlook, LBST, Ottobrunn Germany. pp 6-9.
32. Shamshiri R.R., Weltzien, C., Hameed, I.A., Yule, I.J., Grift, T.E., Balasundram, S.K., Pitonakova, L., Ahmad, D., Chowdhary, G. (٢٠١٨). Research and development in agricultural robotics: a perspective of digital farming, *Int. J. of Agri. & Biol. Eng.* (١١) 4. pp 1-14. DOI: <https://ijabe.org/index.php/ijabe/article/view/4278/1737>
33. Van Henten, E.J., Van't Slot, D.A., Hol, C.W.J., Van Willigenburg, L.G. (٢٠٠٩). Optimal manipulator design for a cucumber harvesting robot, *Journal of Computers and Electronics in Agriculture*. (٦٥). 2. pp 247–257. DOI: [Optimal manipulator design for a cucumber harvesting robot – Science Direct](https://doi.org/10.1016/j.biosystemseng.2018.12.005)
34. Vasconez, J.P., Kantor, G.A., Auat Cheein, F.A. (٢٠١٩). Human–Robot Interaction in Agriculture: a survey and current challenges, *Biosystems Engineering*. (١٧٩) 2. pp 35-48. DOI: <https://doi.org/10.1016/j.biosystemseng.2018.12.005>
35. Yadav, T.N., Reddy, R. O., Prasad, R. C. & Gopal, P. (2020). CROP YIELD AND FERTILIZERS PREDICTION USING DECISION TREE ALGORITHM. In *International Journal of Engineering*



Applied Sciences and Technology. ISSN No. 2455-2143. 5 (1). pp 187-193.

<https://doi.org/10.33564/IJEAST.2020.v05i01.027>

36. Zha, J. (٢٠٢٠). Artificial Intelligence in Agriculture, Journal of Physics: Conference Series. 1693. The 2020 3rd International Conference on Computer Information Science and Artificial Intelligence (CISAI) 2020 25-27 September 2020. Inner Mongolia. China. DOI: <http://dx.doi.org/10.1088/1742-6596/1693/1/012058>
37. www.FAO.org How to Feed the World in 2050. October 2009. P: 2.
38. https://www.fao.org/fileadmin/templates/wsfs/docs/expert_paper/How_to_Feed_the_World_in_2050.pdf