



الجمهورية الجزائرية الديمقراطية الشعبية  
République Algérienne Démocratique Et Populaire  
وزارة التعليم العالي و البحث العلمي  
Ministère De L'Enseignement Supérieur Et De La  
Recherche Scientifique  
المدرسة الوطنية العليا للفلاحة الحراش – الجزائر  
Ecole Nationale Supérieure Agronomique – El Harrach – Alger



Département : Génie rural  
Spécialité : Sciences et techniques des agroéquipements

قسم الهندسة الريفية  
تخصص علوم و تقنيات تجهيزات الفلاحة

## Mémoire de fin d'étude En vue de l'obtention du Diplôme de Master

### THEME

# Contribution to wheat grains weight estimation using computer vision and machine learning

Réaliser par: M.BOUKHELIF Abderazek  
M.BISKER Mohamed Riadh

Soutenu le : 15/11/2021

### Devant le jury composé de :

Encadreur : M. LAABASSI K.	MAA, ENSA
Président de jury : M.MEFTI M.	Pr, ENSA
Examinateurs : M.ETSOURI S.	MCB, ENSA
Examinateurs : M.BRAHIMI M.	MCB, Univ-BBA

Promotion 2016 – 2021

## LIST OF CONTENTS

General introduction.....	14
I. Wheat origin and importance .....	17
I.1 The history of wheat.....	17
I.2 Bread and durum wheat taxonomic classification .....	18
I.3 Bread and durum wheat importance .....	19
II. Wheat production quantity and distribution in Algeria .....	20
II.1 Origin and diversity of wheat in Algeria .....	20
II.2 Production and distribution of wheat in Algeria.....	20
I.4 Registered Varieties of bread and durum wheat.....	23
III. Growth Stages of Wheat Plant .....	24
IV. The morphological description of a wheat plant parts .....	26
IV.1 The wheat spike description.....	26
IV.2 Structure of Wheat Grain.....	27
V. The Thousand Grain Weight .....	28
V.1 History and traditional ways of counting .....	28
V.2 Importance of the thousang grain weight.....	30
V.3 SOURCES OF GRAIN SIZE VARIATIONS.....	32
I. Introduction .....	34
II. What is Artificial Intelligence .....	34
II.1 Artificial Narrow Intelligence (ANI).....	34
II.2 Artificial General Intelligence (AGI) .....	34
II.3 Artificial Super Intelligence (ASI).....	34
III. Artificial narrow intelligence practical usage .....	35
III.1 Expert Systems.....	35
III.2 Machine Learning .....	35
III.3 Others ANI field application.....	36

IV.	Machine Learning Regression Algorithms .....	38
IV.1	The Linear Regression: .....	38
IV.2	Decision Trees .....	39
IV.3	The Support Vector Machine.....	40
IV.4	The k- Nearest Neighbors .....	41
IV.5	The M5.Rules .....	42
IV.6	Multilayer Perceptron .....	43
V.	Notion of distance .....	44
V.1	Euclidean Distance .....	44
V.2	Manhattan Distance .....	45
V.3	Minkowski Distance .....	45
V.4	Hamming Distance.....	45
VI.	Machine learning process step by step.....	46
VI.1	A machine learning workflow .....	46
VI.1.1	Gathering Data.....	46
VI.1.2	Preprocessing and Processing Data.....	46
VI.1.3	Train Model.....	46
VI.1.4	Test Model .....	46
VI.1.5	Improve .....	46
VI.1.6	Prediction.....	46
VI.2	Machine learning problems and challenges .....	46
VI.2.1	Quality and Quantity of data .....	47
VI.2.2	Over and Underfitting .....	47
VI.2.3	Data labeling and annotating.....	48
VI.2.4	Bias .....	48
VII.	Computer vision system methods related to object image analysis .....	48
VII.1	Image acquisition .....	49

VII.2	Preprocessing .....	49
VII.3	Image segmentation .....	50
VII.4	Feature Extraction .....	50
VII.5	Processing and decision-making or Classification .....	51
VIII.	Potential Machine Vision Systems in agriculture .....	51
VIII.1	Grading of Fruits and Vegetables .....	51
VIII.2	Sorting of Fruits and Vegetables.....	52
VIII.3	Related work to the Computer vision and Machine learning technologies in the agricultural field .....	52
I.	Introduction .....	57
II.	MATERIALS .....	59
II.1	Vegetal materials .....	59
II.2	Acquisition materials .....	60
II.3	Weighing material .....	61
II.4	The software .....	62
II.4.1	Computer vision and feature extraction .....	62
II.4.2	The Machine Learning Platform Weka .....	62
III.	Methods.....	63
III.1	The vegetal material collection.....	63
III.2	Image collection.....	64
III.3	Morphological features extraction .....	65
III.4	Data analysis using the platform Weka .....	66
IV.	Experimentation.....	68
IV.1	An overview of our workflow.....	68
IV.2	The feature selection step .....	70
IV.2.1	Correlation Based feature selection .....	70
IV.2.2	Learner Based feature selection .....	71
IV.2.3	Relief Based feature selection .....	73

IV.2.4	Features to keep and to remove .....	74
IV.3	Feature selection results summary.....	74
IV.4	The regression algorithms selection step .....	75
IV.4.1	Setup Weka .....	75
IV.4.2	Evaluating and comparing the results .....	76
	IV.4.2.1 Correlation Coefficient (R) .....	77
	IV.4.2.2 Mean absolute error (MAE) .....	77
	IV.4.2.3 Root mean squared error (RMSE) .....	78
I.	Features selection results and discussion .....	80
I.1	CorrelationAttributeEval results.....	80
I.1.1	Full training set mode .....	81
I.1.2	Cross-validation mode .....	81
I.2	ReliefAttributeEval results.....	82
I.2.1	Full training set mode .....	82
I.2.2	Cross-validation mode .....	82
I.3	WrapperSubsetEval .....	83
I.3.1	Full training set mode .....	84
I.3.2	Cross-validation mode .....	84
I.4	Summary of the feature selection results .....	85
II.	The regression models selection process.....	85
	General Conclusion .....	89
	References .....	90
	Abstract.....	95

## ملخص

الهدف من هذه الرسالة البحثية هو المساهمة في تقدير وزن الألف حبة (TGW) لأربعة أصناف من القمح وهي Simeto و Vitron للقمح الصلب، Arz HD للقمح اللين من خلال الاعتماد على نموذج يتبع وزن الحبة الواحدة (SGW). يستخدم النموذج الخصائص المورفولوجية المستخرجة بواسطة برنامج "SmartGrain" معتدلا على تقنية الرؤية الحاسوبية. إضافة على ذلك، تم إجراء هذا البحث للعثور على أفضل تصنيف انحدار متواصل والذي يعطي القيمة الأكثر واقعية لوزن حبة واحدة (SGW) مع أعلى معامل ارتباط R وأقل خطأ ممكن. تمر مهمة معالجة الصور بعدة خطوات: أولاً، تمت معالجة الحصول على الصور باستخدام ماسح ضوئي، ثم التجزئة واستخراج السمات (الصفات) بواسطة برنامج SmartGrain، ونموذج الانحدار التنبؤي بواسطة تقنية التعلم الآلي باستخدام منصة Weka. كانت الخصائص المورفولوجية (الميزات) هي مدخلات الخوارزميات LR و SVM و MLP و M5P.tree و M5Rules و Bagging. هذه الأخيرة تعطي الأداء الأفضل في مهمة التنبؤ بدقة 93.72%. النتائج التي تم الحصول عليها من قبل المصنفات الأخرى كانت 93.42%， 93.36%， 93.14%， 92.93%， 92.93% على التوالي، وذلك للتنبؤ على مستوى الجنس ( النوع ) مع الخصائص المورفولوجية المختارة، باستخدام كلا الخيارين للاختبار لكونهما يعطيان نفس النتائج.

**الكلمات المفتاحية:** قمح؛ وزن ألف حبة؛ وزن حبة واحدة؛ الخصائص المورفولوجية؛ الرؤية الحاسوبية؛ معالجة الصورة؛ استخراج الميزات؛ نموذج الانحدار؛ التنبؤ؛ التقدير؛ التعلم الآلي؛ الذكاء الاصطناعي.

## Résumé

Le but et l'objectif de cette thèse de recherche est de contribuer à l'estimation du poids mille grains (PMG) de quatre variétés de blé Vitron et Simeto pour le blé dur, Arz, et HD pour le blé tendre en s'appuyant sur un modèle prédisant le Poids de Grain Unique (PUG). Le modèle utilise les caractéristiques morphologiques extraites par un logiciel de vision par ordinateur « SmartGrain ». De plus, cette recherche a été menée pour trouver le meilleur classificateur de régression qui donne la valeur la plus réaliste du Poids de Grain Unique (PUG) avec le coefficient de corrélation R le plus élevé et le moins d'erreur possible. La tâche de traitement d'image passe par de nombreuses étapes : Tout d'abord, l'acquisition d'image a été abordée à l'aide d'un scanner, la segmentation et l'extraction d'attributs par le logiciel SmartGrain, le modèle de régression de prédiction par la technologie Machine Learning en utilisant la plateforme Weka. Les caractéristiques morphologiques étaient les entrées des algorithmes LR, SVM, MLP, M5P.tree, M5Rules.rules et Bagging. Le dernier classificateur est celui qui donne la meilleure prédiction avec une précision de 93,72%. Les résultats obtenus par les autres classificateurs étaient respectivement de 93,42 %, 93,36 %, 93,14 %, 92,93 %, 92,93 %, et ces résultats au niveau du Genre, avec les caractéristiques morphologiques choisissez, en utilisant les deux options de test comme ils donnent les mêmes résultats.

**Mots-clés :** Blé ; Poids de Mille Grains ; Poids de Grain Unique ; Caractéristiques morphologiques ; Vision par ordinateur ; Traitement d'image ; Extraction de fonctionnalités ; Régression ; Prédiction ; Apprentissage automatique ; Intelligence artificielle.

## Abstract

The aim and the objective of this research thesis is to contribute in the estimation of the thousand grain weight (TGW) of four varieties of wheat Vitron and Simeto for durum wheat, Arz, and HD for bread wheat by relying on a model that predict a Single Grain Weight (SGW). The model use the morphological characteristics extracted by a Computer Vision software “SmartGrain”. Furthermore, this research was carried out to find the best regression classifier which gives the most realistic value of a Single Grain Weight (SGW) with the highest correlation coefficient R and the least possible error. The image processing task pass by numerous steps: First, the image acquisition was been tackled using a scanner, the segmentation and the attributes extraction by SmartGrain software, the prediction regression model by Machine Learning technology using Weka Platform. Morphological characteristics (features) were the inputs for the LR, SVM,

MLP, M5P.tree, M5Rules.rules algorithms and the Bagging one. The last classifiers, gives the best in the prediction task with an accuracy of 93.72%. The results obtained by the others classifiers were 93.42%, 93.36%, 93.14%, 92.93%, 92.93% respectively, and that for predicting at the Genus level with the choosen morphological characteristics, using both of the test option as they give the same results.

**Keywords:** Wheat; Thousand Grain Weight; Single Grain Weight; Morphological characteristics; Computer Vision; Image processing; Features extraction; Regression; Prediction; Machine Learning; Artificial Intelligence.