



الجمهورية الجزائرية الديمقراطية الشعبية

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET
POPULAIRE

وزارة التعليم العالي والبحث العلمي

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA
RECHERCHE SCIENTIFIQUE

المدرسة الوطنية العليا للفلاحة الحراش – الجزائر

École Nationale Supérieure Agronomique



Département: Génie Rural

Spécialité: Agriculture Numérique

قسم: الهندسة الريفية

تخصص: زراعة رقمية

Mémoire de fin d'étude

Pour l'obtention du diplôme Master

THÈME

Improving the Accuracy of Cotton Water Stress Detection on Drone-Captured Data.

Présenté par : **Mohamed Amir Bouzid**

Soutenu le : 08/10/2025

Devant le jury composé de :

Président :	Mr. SAADAoui Mohamed	(Professeur – ENSA)
Promoteur :	Mr. DELLI Reda	(MCB – ENSA)
Co-Promoteur :	Mr. AIT ALI YAHIA Yassine	(MCB – ESI)
Examineurs :	Mr. ETSOURI Salim	(MCA – ENSA)
	Mr. LARIBI Abdelkader	(MCA – ENSA)

TABLE OF CONTENTS

DEDICATION	3
THANKS.....	3
TABLE OF CONTENTS	8
List of Tables.....	10
List of Figures.....	11
List of Abbreviations.....	12
GENERAL INTRODUCTION	1
CHAPTER I: Cotton cultivation: agronomic aspects and vegetative development	
Introduction	5
I.1 COTTON CULTIVATION AND ITS CHARACTERISTICS	5
I.1.1 History	6
1.1.1.2 Soil and climate requirements and development cycle of cotton	8
1.1.2 Cultivation Practices	10
1.1.3 Water Stress in Cotton: Physiological and Morphological Responses	11
1.1.4 Context and Challenges of Cotton in Algeria and the United States.....	15
CONVOLUTIONAL NEURAL NETWORKS	27
CHAPITRE II: CONVOLUTIONAL NEURAL NETWORKS	
Introduction.....	28
II.1 Input Layer and Data Preprocessing.....	29
II.2 Convolutional Layers	30
II.2.1 Mathematical Foundation of Convolution	30
Conclusion.....	40
CHAPTER III: MATERIALS AND METHODS	
Introduction.....	42
III.1 Dataset and Data Acquisition	42
III.2 Data Preprocessing Pipeline	45
III.3 Experimental Setup and Hardware Configuration	49
III.4 Model Development and Architecture	51
Conclusion.....	57
CHAPTER IV: Results and Discussion	
Introduction.....	59
IV.1 PREDICTION RESULTS	59
IV.1.1 Evaluation Metrics and Performance Assessment Framework.....	59

IV.1.2 Training and Testing results	61
IV.2 COMPARATIVE RESULTS.....	75
IV.3 DISCUSSION	76
IV.3.1 Performance Analysis	76
IV.3.2 Methodological Contributions and Innovations	78
IV.3.3 Temporal Consistency and Agricultural Implications	78
IV.3.4 Limitations and Future Research Directions	79
GENERAL CONCLUSION	82
GENERAL CONCLUSION	83
BIBLIOGRAPHIC REFERENCES	83

ABSTRACT:

This dissertation addresses limitations in cotton water stress detection using UAV-captured RGB imagery and advanced deep learning techniques. Building upon Niu et al. (2024), who achieved 91% accuracy in cotton irrigation classification, this study develops an enhanced framework using over 21,000 UAV images collected across four sampling dates from experimental plots in Lubbock, Texas.

We implemented an InceptionV3-based CNN with transfer learning and fine-tuning methodologies to distinguish between four irrigation management strategies: rainfed, fully irrigated, percent deficit irrigation, and time delay irrigation. Our two-phase training strategy combined ImageNet pre-trained features with selective layer unfreezing for domain-specific optimization.

Results demonstrate exceptional performance improvements, achieving 96% overall accuracy across all temporal datasets compared to the 91% baseline. The model maintained temporal consistency with zero performance variance across sampling dates, indicating successful capture of phenology-invariant spectral signatures. Class-specific analysis revealed superior discrimination capabilities with rainfed conditions achieving 95-99% F1-scores and fully irrigated areas reaching 97-100% precision.

Key Words: Cotton, Convolutional Neural Networks, Irrigation, Precision Agriculture, Remote Sensing, UAV.

ملخص:

تهدف هذه الأطروحة إلى تحسين دقة كشف الإجهاد المائي في القطن وتصنيف معاملات الري باستخدام صور RGB الملتقطة بواسطة المركبات الجوية بدون طيار (UAV) وتقنيات التعلم العميق المتقدمة. بناءً على العمل الأساسي لـ Landivar و Niu و (Duffield 2024)، الذين حققوا دقة 91% في تصنيف ري القطن، تتناول هذه الدراسة القيود الأدائية الكبيرة الملاحظة في نموذجهم، خاصة انخفاض الدقة لمعاملات الري النقصي في تواريخ الأخذ المتأخرة. باستخدام مجموعة بيانات شاملة تضم أكثر من 21,000 صورة RGB لمحاصيل القطن ملتقطة بواسطة الطائرات بدون طيار، تم جمعها عبر أربعة تواريخ أخذ عينات حاسمة من قطع تجريبية في لوبوك، تكساس .

قمنا بتنفيذ شبكة عصبية تطويرية قائمة على InceptionV3 مع منهجيات التعلم بالنقل والضبط الدقيق للتمييز بين أربع استراتيجيات إدارة الري: المطري، المروي بالكامل، الري النقصي النسبي، والري المؤجل زمنياً. استراتيجيات التدريب ثنائية المراحل تجمع بين ميزات ImageNet المدربة مسبقاً مع إلغاء التجميد الانتقائي للطبقات للتحسين المحدد للمجال .

تُظهر النتائج تحسينات أداء استثنائية حيث حققت 96% دقة إجمالية عبر جميع مجموعات البيانات الزمنية مقارنة بخط الأساس 91%. حافظ النموذج على اتساق زمني مع تباين أداء صفري عبر تواريخ الأخذ، مشيراً إلى التقاط ناجح للتوقعات الطيفية الثابتة فينولوجياً. كشف التحليل المحدد للفئات عن قدرات تمييز فائقة حيث حققت الظروف المطرية نقاط F1 بنسبة 95-99% والمناطق المروية بالكامل وصلت إلى دقة 97-100%.

كلمات مفتاحية:

الزراعة الدقيقة، القطن، الري، الشبكات العصبية الالتفافية، الطائرات بدون طيار، الكشف عن بُعد.

Résumé :

Cette thèse aborde les limitations de la détection du stress hydrique du cotonnier en utilisant l'imagerie RGB capturée par UAV et des techniques avancées d'apprentissage profond. S'appuyant sur les travaux de Niu et al. (2024), qui ont atteint 91% de précision dans la classification de l'irrigation du coton, cette étude développe un cadre amélioré utilisant plus de 21 000 images UAV collectées sur quatre dates d'échantillonnage dans des parcelles expérimentales à Lubbock, Texas.

Nous avons implémenté un CNN basé sur InceptionV3 avec apprentissage par transfert et méthodologies d'ajustement fin pour distinguer quatre stratégies de gestion d'irrigation : pluviale, entièrement irriguée, irrigation déficitaire en pourcentage, et irrigation à délai temporel. Notre stratégie de formation en deux phases combine des caractéristiques pré-entraînées d'ImageNet avec un dégel sélectif de couches pour une optimisation spécifique au domaine.

Les résultats démontrent des améliorations de performance exceptionnelles, atteignant 96% de précision globale sur tous les ensembles de données temporelles comparativement à la référence de 91%. Le modèle a maintenu une cohérence temporelle avec une variance de performance nulle à travers les dates d'échantillonnage, indiquant une capture réussie de signatures spectrales invariantes à la phénologie. L'analyse spécifique aux classes révèle des capacités de discrimination supérieures avec les conditions pluviales atteignant 95-99% de F1-scores et les zones entièrement irriguées atteignant 97-100% de précision.

Mots clés : Agriculture de précision, Coton, Détection à distance, Irrigation, Réseaux de neurones convolutifs, UAV.