



Estimación de parámetros biofísicos de interés para la mejora de trigo usando inteligencia artificial

O. E. Apolo-Apolo¹, M. Pérez-Ruiz¹, J. Martínez-Guanter², G. Egea¹

¹ Dpto. Ingeniería Aeroespacial y Mecánica de Fluido, Universidad de Sevilla, Ctra. Sevilla-Utrera km1 Sevilla 41013; eapolo@us.es ; manuelperez@us.es; jmartinez@us.es; gegea@us.es.

² Agrolanning Agricultura Inteligente S.L. Programa Torres-Quevedo 2017 (PTQ-17-09506).

Resumen: La estimación de parámetros biofísicos como el índice de área foliar (IAF) ha sido un reto en los últimos años. Los métodos directos e indirectos existentes hasta el momento son costosos tanto en tiempo como en dinero. El desarrollo en los últimos años de las plataformas de fenotipado ha abierto la posibilidad de crear nuevas herramientas que ayuden a los mejoradores a tomar decisiones. El objetivo de este trabajo ha sido el desarrollo de una red neuronal artificial (ANN) para estimar IAF a partir de imágenes RGB y comparar su poder predictivo con otro método indirecto basado en el uso de imágenes hemisféricas y la teoría de la fracción de huecos. Los valores de IAF estimados con ambos métodos indirectos se compararon con medidas de IAF obtenidas de forma no destructiva con una relación alométrica determinada previamente en las parcelas de ensayo que explica en un 93% la variabilidad del área foliar unitaria observada (RMSE = 0.22 cm²). Los valores de IAF obtenidos con imágenes hemisféricas obtuvieron, en comparación con los medidos con la relación alométrica, un error próximo al 19%. Sin embargo, los valores de IAF obtenidos con la ANN obtuvieron un error notablemente inferior y próximo al 7%. Estos resultados muestran el gran potencial del modelo desarrollado, el cual puede continuar mejorando a través de la optimización del dataset utilizado.

Palabras clave: LAI, ANN, fenotipado, inteligencia artificial, *Deep learning*.

1. Introducción

Es un hecho constatado que la población humana aumentará notablemente en las próximas décadas [1]. En este contexto será necesario incrementar la producción agrícola [2] en un escenario de escasez de recursos y preservación del medio ambiente [3]. Dicho aumento deberá producirse en todos los cultivos, pero muy especialmente en aquellos cultivos básicos como el trigo, el cual aporta en torno al 20% de la ingesta calórica diaria para un ser humano [3,4]. El aumento medio anual del rendimiento en trigo que los mejoradores han conseguido en las últimas décadas a nivel mundial oscila en torno al 0.9%, mientras que las previsiones demandan que dicho aumento debería de ser en torno al 2.4% para satisfacer la creciente demanda mundial de alimentos [4–6]. Para salvar esta diferencia, los mejoradores demandan gran cantidad de información de los cultivos que les ayuden a tomar decisiones a la hora de seleccionar nuevas variedades [7]. Sin embargo, mucha de esta información es obtenida en laboratorios y bajo condiciones controladas, lo cual difiere del comportamiento en campo [7]. Por otra parte, la información que es obtenida en campo se hace de forma manual basándose en la experiencia de un técnico especializado la cual puede ser fuente de error [8]. En este contexto, el fenotipado de alto rendimiento tanto en plataformas terrestres como áreas [9–11], que

permite la evaluación precisa con sensores remotos de las respuestas a estreses abióticos y bióticos de los cultivos, han emergido como una herramienta prometedora, ya que permite la monitorización de parámetros biofísicos de manera rápida, precisa, no destructiva y barata [12]. Entre la gran cantidad de parámetros fisiológicos y estructurales que se pueden monitorear o estimar a nivel de planta, el Índice de Área Foliar (IAF) es un parámetro biofísico del cultivo que tiene gran importancia agronómica y es un indicador de la capacidad fotosintética del cultivo, estando estrechamente relacionado con la producción final [13]. Su valor, se puede obtener de forma directa dividiendo el área foliar de un cultivo y el área de suelo sobre el cual se encuentra establecido [14,15]. Para el cálculo del IAF tradicionalmente se han utilizado métodos directos (destructivos) e indirectos (no destructivos). Los métodos directos, además de ser destructivos, requieren mucho tiempo y son costosos [16], por lo que su uso queda normalmente relegado a la validación de métodos indirectos (e.g. análisis de la fracción de huecos en fotografías hemisféricas), utilizados con mucha mayor frecuencia [17]. Sin embargo, a pesar de que los métodos indirectos son bastante precisos, estos necesitan un post-procesamiento que consume mucho tiempo [18]. El desarrollo de redes neuronales basadas en aprendizaje profundo o *Deep Learning* (DL), un subconjunto del aprendizaje automático o *Machine Learning* (ML), y concretamente las redes convolucionales (CNN o CovNet) se presentan como alternativa para hacer estimaciones de IAF [19]. Este tipo de redes permiten transferir lo aprendido por la red en un escenario en el que dispone de *datasets* o conjuntos de datos de gran tamaño a otros escenarios con menores datos con el propósito de resolver un problema concreto, técnica conocida como *transfer learning* [20]. Por tanto, el objetivo del presente trabajo ha sido crear un modelo basado en CNNs a partir de una arquitectura de red existente y entrenada para estimar el IAF a partir de imágenes RGB.

2. Materiales y métodos

2.1. Descripción de la parcela experimental

El estudio tuvo lugar en una parcela experimental de la empresa Agrovegetal S.A. (finca La Aceñuela), en el término municipal de Escacena del Campo (Huelva) (37.457333, -6.363585). Dicho ensayo tuvo lugar durante la campaña 2017/2018, sembrándose el 25 de noviembre de 2017, y cosechándose el 15 de junio de 2018. Las variedades se sembraron inicialmente en micro-parcelas de 6.50 m de largo y 1.20 m de ancho. Posteriormente, se segaron químicamente para establecer unas dimensiones definitivas de 6.00 m de largo y 1.20 m de ancho. El ensayo estuvo compuesto por las siguientes 10 variedades de trigo blando (*Triticum aestivum* L.): Antequera, Conil, Galera, Gazul, Marchena, Montalbán, THA 3753, THA 3829, Tujena y Valbona. Se establecieron tres repeticiones por variedad, siendo 30 el número total de micro-parcelas que formaron parte del estudio. Las condiciones de cultivo del trigo para toda la campaña fueron en secano como suele ser habitual en la región. En este sentido el único aporte hídrico que recibió el cultivo procedió de la precipitación, unos 509 mm, la cual se repartió entre unos 10-12 días antes de la siembra hasta el día de la cosecha.

2.2. Medidas manuales y relación alométrica

La determinación del IAF mediante métodos destructivos es en muchas ocasiones la única forma de poder validar las estimaciones de IAF realizadas mediante métodos indirectos. En este trabajo, debido a que la destrucción de plantas de trigo harinero en las parcelas para estimar de forma directa el IAF afectaría a la determinación del potencial productivo de cada variedad, se decidió recolectar tres plantas por micro-parcela de la zona que posteriormente se segaría. Las plantas recolectadas fueron introducidas inmediatamente en bolsas de plástico y éstas, a su vez, en una nevera portátil refrigerada con placas de hielo. Posteriormente, una vez en el laboratorio, se determinaron las dos dimensiones principales de cada hoja (longitud máxima y

anchura máxima) y el área foliar unitaria con el medidor Li-Cor 3100 (Li-Cor Inc., Lincoln, Nebraska, USA). Finalmente, una vez conocidas las dimensiones principales y el área foliar unitaria de las hojas muestreadas se buscaron relaciones empíricas que permitiesen predecir con precisión el área foliar de hojas de trigo mediante la medida en campo de sus dimensiones principales.

2.3. Toma de fotografías

Durante los días del año (DDA) 25, 40, 53, 80, 87, 93, 108 y 117, se tomaron dos fotografías por micro-parcela utilizando la cámara de un móvil Huawei P8 en condiciones de luz natural. La primera fotografía se tomó desde el centro de la micro-parcela mirando hacia el cielo (up-view). Esta imagen fue de tipo hemisférico, ya que para tomarla se utilizó una lente tipo ojo de pez a través de la cámara del móvil. La otra fotografía fue adquirida usando únicamente la cámara del móvil posicionada en el centro de la micro-parcela a una altura sobre el cultivo de 0.75 m y mirando hacia abajo (down-view). Para la toma de esta última fotografía, con el fin de validar el uso de esta metodología en plataformas de fenotipado masivo, se utilizó una plataforma de fenotipado desarrollada por los autores para su utilización en programas de mejora de trigo (Figura 1). La resolución de ambas fotografías fue de 4000x3000 píxeles.



Figura 1. Fotografía obtenida con la cámara del teléfono Huawei P8 utilizando lente de ojo de pez (A), fotografía obtenida con la cámara del Huawei P8 sin lente adicional (B) y plataforma de fenotipado utilizada en B (C).

2.4. Obtención del Índice de Área Foliar del maíz a partir de la relación alométrica

El primer día que se tomaron fotografías (DDA 25), se seleccionaron y se marcaron al azar tres plantas de cada micro-parcela dentro del área que no se iba a segar. Posteriormente, con una cinta métrica se midieron las dimensiones principales de todas las hojas de cada planta, acción que fue repetida durante los DDA 87 y 108. Estas medidas fueron utilizadas para determinar el área foliar de cada hoja mediante la relación alométrica descrita en el epígrafe 2.2. El área foliar total de cada planta se determinó sumando el área unitaria de todas las hojas de una planta. El Índice de Área Foliar de las treinta parcelas del estudio fue calculado a partir de la siguiente expresión:

$$IAF = \frac{PLA (m^2)}{MP (m^2)}$$

donde PLA es el área foliar de la planta y MP el marco de plantación.

2.5. Construcción de la ANN, software y equipo utilizado

La arquitectura de la ANN utilizada en este proyecto está basada en el trabajo realizado por Ahmed y Moustafa (2016) [21], donde se combinan imágenes y texto como atributos para entrenar una red neuronal (Figura 2). Para el entrenamiento de la red neuronal en este trabajo se emplearon 180 imágenes (down-view) obtenidas en 6 fechas distintas y los valores de IAF calculados a partir de la relación alométrica (DDA 87) y los obtenidos a partir de las imágenes (up-view) usando el software Can-Eye [14] para los DDA 40, 53, 80, 93, y 117). Para lograr la combinación de datos numéricos e imágenes se utilizó la librería Keras, una librería de redes neuronales de código abierto escrita en lenguaje de programación Python [22]. Hay poca literatura científica en la que se utilice la combinación de datos mixtos para hacer predicciones utilizando Keras, ya que la mayor parte de modelos utilizan la interfaz de programación de aplicaciones o API secuencial desarrollada para datos secuenciales [23]. Sin embargo, existe la API funcional que es utilizada para modelos más complejos que utilizan datos no secuenciales [23,24]. En este caso, partiendo de los datos de entrada, se utilizan dos redes neuronales, la Multi-Layer Perceptron (MPL) que se encarga de los datos y la Convolutional Neural Network (CNN) que trabaja con las imágenes. Posteriormente estas dos redes se concatenan y junto con una Fully-Connected Layer (FC) más una función de activación se predice el valor del IAF. El hardware utilizado para todo el proceso de modelado fue el MacBook Pro (MacOs High Sierra 10.13.4) equipado con un procesador de 2.5 GHz Intel Core i7, 16 GB de memoria RAM y una gráfica AMD Radeon R9 M370X 2048 MB Intel Iris Pro 1536 MB.

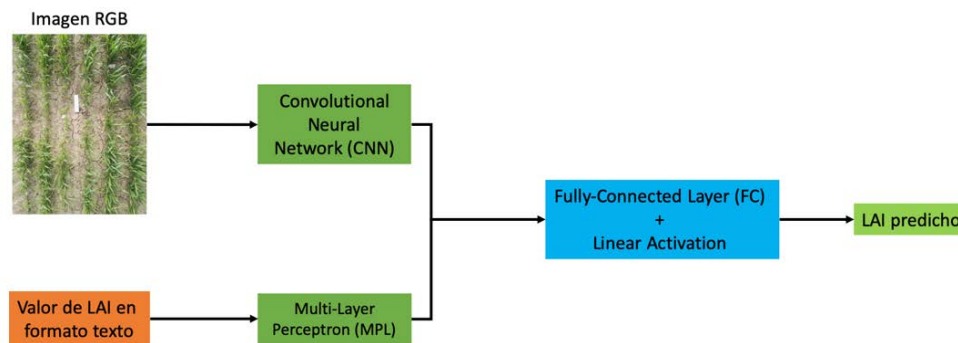


Figura 2. Croquis de la arquitectura de la red neuronal utilizada para predecir el valor del LAI a partir de imágenes RGB.

2.6. Análisis estadístico

La comparación entre los valores de IAF obtenidos con el software Can-Eye y con la ANN y los estimados de forma directa con la relación alométrica para el (DDA 108) se ha llevado a cabo mediante dos valores estadísticos: la raíz del error cuadrático medio (RMSE) y el error porcentual absoluto medio (MAPE).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - S_i)^2}{N}} \quad MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|IAFr - IAFe|}{IAFr}$$

donde N se refiere al número de valores comparados, O_i el valor observado i , S_i el valor predicho i , \bar{O} el valor medio de los valores observados, $IAFr$ el valor real del IAF y $IAFe$ el valor estimado.

3. Resultados y discusión

3.1. Relación alométrica utilizando las dimensiones características de la hoja y el área foliar unitaria

La obtención de una relación alométrica que permita estimar el área foliar de hojas individuales de trigo de forma no destructiva, resulta de gran interés para la validación de otros métodos no destructivos en ensayos donde no se pueda destruir el material vegetal, como es el caso de un ensayo de variedades donde la variación en el número de plantas por micro-parcela alteraría los resultados de productividad de las variedades. En este sentido, el análisis de las dimensiones características y la superficie individual de hojas de trigo ha permitido obtener una relación empírica capaz de predecir el 93% de la variabilidad del área foliar unitaria observada (Figura 3). La relación es una ecuación de primer grado de la forma $Y = ax$, donde la variable independiente (x) se determina a partir del producto de la anchura máxima (W) y la longitud de la hoja (L), y el parámetro a toma el valor 0.92. Esta relación ha sido propuesta con frecuencia para determinar de forma no destructiva el área individual de hojas de trigo, si bien es cierto que el valor de a propuesto por otros autores es de 0.75 [25], ligeramente inferior al obtenido con el material vegetal empleado en este estudio. Así mismo el error cuadrático medio (RMSE = 0.22 cm²) obtenido indica un buen ajuste del modelo.




Figura 3. Relación alométrica obtenida entre las dimensiones características de la hoja de trigo y el área foliar unitaria. W: anchura máxima de la hoja; L: longitud de la hoja.

3.2. Validación de las estimas de IAF realizadas mediante la relación alométrica

Al observar las estimaciones de IAF obtenidas en la Tabla 1, se puede comprobar que son valores muy similares a los obtenidos por otros autores en los mismos periodos fenológicos [26]. El error obtenido en las estimas de IAF usando el software Can-Eye es superior al obtenido con la ANN, lo que demuestra el gran potencial de utilizar esta metodología, que no solo es más rápida, sino que acorde a los datos obtenidos es más precisa.

Tabla 1. Estimaciones de LAI obtenidas con Can-Eye y con la ANN frente al obtenido con la relación alométrica para el (DDA108).

Variedad	IAF medido	IAF estimado con Can-Eye		IAF estimado con ANN	
	Valor medio	Valor medio	Error (%)	Valor medio	Error (%)
GAZUL	5.980	5.12	14.38	5.56	7.02
GALERA	5.913	6.29	6.43	5.33	9.86
VALBONA	6.343	5.02	20.86	5.86	7.62
ANTEQUERA	6.383	4.53	29.09	6.15	3.66
CONIL	5.857	6.29	7.46	5.67	3.19
MARCHENA	6.883	5.02	27.07	6.34	7.89
TUJENA	6.853	5.53	19.36	6.32	7.78
MONTEMAYOR	6.367	5.72	10.21	5.82	8.59
THA3752	7.090	4.81	32.20	6.77	4.51
THA3820	5.993	4.78	20.30	5.47	8.73

Los errores de casi un 10% obtenidos utilizando la ANN sugieren que aún hay margen de mejora para optimizar el modelo. Esto se podría conseguir aumentando el número de imágenes del dataset, modificando los pesos de la red neuronal, introduciendo nuevos valores como (altura, número de hojas, días después de la siembra, estado fenológico, etc.) en las entradas de la red neuronal.

4. Conclusiones

Los resultados obtenidos demuestran el alto potencial que hay para estimar el IAF utilizando imágenes RGB adquiridas desde una plataforma de fenotipado. En el futuro, para mejorar la estimación del IAF, se podría aumentar el número de imágenes utilizadas como dataset para entrenar la ANN, así como incorporar otros atributos en la capa MPL de la red neuronal tales como: altura del cultivo, estado fenológico, días después de la siembra, fracción de cubierta, etc., para observar si estas modificaciones también influyen en la precisión de la estimación.

Una forma alternativa de aumentar el dataset podría ser utilizando videos grabados desde la plataforma a medida que ésta se desplaza sobre las micro-parcelas. Posteriormente, se extraerían los frames de cada video, lo que permitiría representar la variabilidad de IAF de una misma micro-parcela.

5. Agradecimientos

Este trabajo ha sido posible gracias al proyecto *Pressing* (Referencia: AGL2016-78964-R) financiado por el Ministerio de Ciencia, Innovación y Universidades. Los autores agradecen a la empresa Agrovegetal S.A. y a su Director Técnico D. Ignacio Solís Martel la gran ayuda prestada en el desarrollo del trabajo. Los autores también quieren agradecer el contrato Torres Quevedo (PTQ-17-09506) concedido a JMG y al contrato predoctoral para el desarrollo del programa de I+D+i de la Universidad de Sevilla (IV.3 2017) concedido a OEAA.

Referencias

1. Zipper, S.C.; Qiu, J.; Kucharik, C.J. Drought effects on US maize and soybean production: Spatiotemporal patterns and historical changes. *Environ. Res. Lett.* 2016, 11, 1–11, doi:10.1088/1748-9326/11/9/094021.
2. Fischer, G. Transforming the global food system. *Nature* 2018, 562, 501–502, doi:10.1038/d41586-018-07094-6.
3. Foley, J.A.; Ramankutty, N.; Brauman, K.A.; Cassidy, E.S.; Gerber, J.S.; Johnston, M.; Mueller, N.D.; O'Connell, C.; Ray, D.K.; West, P.C.; et al. Solutions for a cultivated planet. *Nature* 2011, 478, 337–342, doi:10.1038/nature10452.
4. Gonzalez-Dugo, V.; Hernandez, P.; Solis, I.; Zarco-Tejada, P.J. Using high-resolution hyperspectral and thermal airborne imagery to assess physiological condition in the context of wheat phenotyping. *Remote Sens.* 2015, 7, 13586–13605, doi:10.3390/rs71013586.
5. Ray, D.K.; Mueller, N.D.; West, P.C.; Foley, J.A. Yield Trends Are Insufficient to Double Global Crop Production by 2050. *PLoS One* 2013, 8, doi:10.1371/journal.pone.0066428.
6. Reynolds, M. *Climate Change & Crop Production*; 2010; ISBN 9781845936334.
7. Araus, J.L.; Cairns, J.E. Field high-throughput phenotyping: The new crop breeding frontier. *Trends Plant Sci.* 2014, 19, 52–61, doi:10.1016/j.tplants.2013.09.008.
8. Reeves, T.G.; Cassaday, K. History and past achievements of plant breeding. *Aust. J. Agric. Res.* 2002, 53, 851–863, doi:10.1071/AR02038.
9. White, J.W.; Andrade-Sanchez, P.; Gore, M.A.; Bronson, K.F.; Coffelt, T.A.; Conley, M.M.; Feldmann, K.A.; French, A.N.; Heun, J.T.; Hunsaker, D.J.; et al. Field-based phenomics for plant genetics research. *F. Crop. Res.* 2012, 133, 101–112, doi:10.1016/j.fcr.2012.04.003.
10. Andrade-Sanchez, P.; Gore, M.A.; Heun, J.T.; Thorp, K.R.; Carmo-Silva, A.E.; French, A.N.; Salvucci, M.E.; White, J.W. Development and evaluation of a field-based high-throughput phenotyping platform. *Funct. Plant Biol.* 2014, 41, 68–79, doi:10.1071/FP13126.
11. Chapman, S.; Merz, T.; Chan, A.; Jackway, P.; Hrabar, S.; Dreccer, M.; Holland, E.; Zheng, B.; Ling, T.; Jimenez-Berni, J. Pheno-Copter: A Low-Altitude, Autonomous Remote-Sensing Robotic Helicopter for High-Throughput Field-Based Phenotyping. *Agronomy* 2014, 4, 279–301, doi:10.3390/agronomy4020279.
12. Reynolds, D.; Baret, F.; Welcker, C.; Bostrom, A.; Ball, J.; Cellini, F.; Lorence, A.; Chawade, A.; Khafif, M.; Noshita, K.; et al. What is cost-efficient phenotyping? Optimizing costs for different scenarios. *Plant Sci.* 2019, 282, 14–22, doi:10.1016/j.plantsci.2018.06.015.
13. Gonsamo, A.; Walter, J.M.; Chen, J.M.; Pellikka, P.; Schleppi, P. A robust leaf area index algorithm accounting for the expected errors in gap fraction observations. *Agric. For. Meteorol.* 2018, 248, 197–204, doi:10.1016/j.agrformet.2017.09.024.
14. Weiss, M.; Baret, F.; Smith, G.J.; Jonckheere, I.; Coppin, P. Review of methods for in situ leaf area index (LAI) determination. *Agric. For. Meteorol.* 2004, 121, 37–53, doi:10.1016/j.agrformet.2003.08.001.
15. Ed. Watson, D.; Listman, M. CGIAR research programme Maize 2012 annual report. Mexico, D.F.: CIMMYT. Vasa 2012.
16. Sonnentag, O.; Talbot, J.; Chen, J.M.; Roulet, N.T. Using direct and indirect measurements of leaf area index to characterize the shrub canopy in an ombrotrophic peatland. *Agric. For. Meteorol.* 2007, 144, 200–212, doi:10.1016/j.agrformet.2007.03.001.
17. Weiss, M.; Baret, F.; Smith, G.J.; Jonckheere, I.; Coppin, P. Review of methods for in situ leaf area index (LAI) determination Part II. Estimation of LAI, errors and sampling. *Agric. For. Meteorol.* 2004, 121, 37–53, doi:10.1016/j.agrformet.2003.08.001.
18. Demarez, V.; Duthoit, S.; Baret, F.; Weiss, M.; Dedieu, G. Estimation of leaf area and clumping indexes of crops with hemispherical photographs. *Agric. For. Meteorol.* 2008, 148, 644–655, doi:10.1016/j.agrformet.2007.11.015.
19. Xavier, F.; Boldú, P. A review of the use of convolutional neural networks in agriculture Social Internet of Things View project P-SPHERE project View project. *Artic. J. Agric. Sci.* 2018, doi:10.1017/S0021859618000436.

X CONGRESO IBÉRICO DE AGROINGENIERÍA
X CONGRESSO IBÉRICO DE AGROENGENHARIA
3 – 6 septiembre 2019, Huesca - España

20. Mehdipour Ghazi, M.; Yanikoglu, B.; Aptoula, E. Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing* 2017, 235, 228–235, doi:10.1016/j.neucom.2017.01.018.
21. Ahmed, E.; Moustafa, M. House price estimation from visual and textual features. 2016.
22. Gopalakrishnan, K.; Khaitan, S.K.; Choudhary, A.; Agrawal, A. Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection. *Constr. Build. Mater.* 2017, 157, 322–330, doi:10.1016/j.conbuildmat.2017.09.110.
23. Rosebrock, A. *Deep learning for computer vision*; 2017; ISBN 2013436106.
24. Gulli, A.; Pal, S. *Deep Learning with Keras*; Packt Publishing: Birmingham, 2017; Vol. 73; ISBN 1531-7714 ST - Mixing interview and questionnaires methods: Practical problems in aligning data.
25. Chanda, S. V; Singh, Y.D. Estimation of leaf area in wheat using linear measurements. *Plant Breedin Seed Sci.* 2002, 46, 75–79.
26. Asrar, G.; Kanemasu, E.T.; Yoshida, M. Estimates of leaf area index from spectral reflectance of wheat under different cultural practices and solar angle. *Remote Sens. Environ.* 1985, 17, 1–11, doi:10.1016/0034-4257(85)90108-7.