

EPSILON-AND NU-SUPPORT VECTOR REGRESSION ALGORITHMS FOR MOLDBOARD PLOW DRAFT-FORCE PREDICTION

ALGORITMOS DE VECTORES SOPORTE PARA REGRESIÓN EPSILON Y NU PARA PREDICCIÓN DE FUERZA DE TIRO EN UN ARADO DE VERTEDERAS

Abdulwahed M. **Aboukarima**^{1,2*}, Saleh A. **Al-Suhaibani**¹, Ibrahim S. **Tabash**¹

¹Department of Agricultural Engineering, College of Food and Agriculture Sciences, King Saud University, P.O. Box 2460, Riyadh 11451, Saudi Arabia. (aboukarima@gmail.com).

²Agricultural Engineering Research Institute, Agricultural Research Centre, Egypt.

ABSTRACT

The draft force acting on a moldboard plow plays an important role in the design of more efficient plows to facilitate attainment of optimum results when implementing size matching to estimate the required tractor power. The purpose of this study, therefore, was to investigate ε -SVR and ν -SVR algorithms, in predicting the draft force acting on the moldboard plow considering plowing speed, plowing depth, and soil moisture content as governing parameters. The experimental design was randomized block with two replications and the treatments were: 1) three plowing speeds, 2.71, 3.21, and 4.32 km h⁻¹; 2) three tillage depths, 9, 14, and 16 cm; and 3) three levels of soil-moisture content, 9.9, 10.9, and 13.2% db. The data were analyzed with the SPSS Software and treatment means were compared with the Tukey test ($p \leq 0.05$). The maximum draft force, 8.57 kN, was observed under conditions corresponding to a plowing speed of 4.32 km h⁻¹, 16-cm plowing depth, and soil-moisture content of 9.9% db. A prediction model was developed using two learning algorithms, ε -SVR and ν -SVR, to facilitate accurate prediction of the moldboard-plow draft force through use of different kernel functions: linear, polynomial, sigmoid, and radial-basis-function kernels. The prediction model based on ε -SVR and the use of the radial basis function demonstrated optimum performance with regards to draft-force prediction, and key parameters corresponding to the said optimum model assume following values: $C = 1604.774$, $\varepsilon = 0.001$, $\lambda = 0.123$, and $p = 0.012$. The total analysis run time was 3.93 min. The root mean squared error in predictions made by the proposed model was 0.288 kN, and the correlation coefficient between actual and predicted draft forces was 0.969, thereby confirming a satisfactory performance of the proposed model.

RESUMEN

La fuerza de tiro que actúa sobre un arado de vertederas juega un papel importante en el diseño de arados más eficientes para facilitar el alcance de resultados óptimos al implementar la coincidencia de tamaño como estimador de la potencia requerida del tractor. Por lo tanto, el propósito de este estudio fue investigar los algoritmos ε -SVR y ν -SVR, para predecir la fuerza de tiro que actúa sobre el arado de vertederas considerando la velocidad de arado, la profundidad de arado y el contenido de humedad del suelo como parámetros determinantes. El diseño experimental fue en bloques aleatorizados con dos repeticiones y los tratamientos fueron: 1) tres velocidades de arado, 2.71, 3.21 y 4.32 km h⁻¹; 2) tres profundidades de labranza, 9, 14 y 16 cm; y 3) tres niveles de contenido de humedad del suelo, 9.9, 10.9 y 13.2% bs. Los datos se analizaron con el Software SPSS y las medias de tratamiento se compararon con la prueba de Tukey ($p \leq 0.05$). La fuerza de tiro máxima, 8.57 kN, se observó en condiciones correspondientes a una velocidad de arado de 4.32 km h⁻¹, una profundidad de arado de 16 cm y un contenido de humedad del suelo de 9.9% bs. Un modelo de predicción se desarrolló y se usaron dos algoritmos de aprendizaje, ε -SVR y ν -SVR, para facilitar la predicción precisa de la fuerza de tiro del arado de vertederas mediante el uso de diferentes funciones de núcleo: lineal, polinomial, sigmoide, y núcleos de funciones con base radial. El modelo de predicción basado en ε -SVR con el uso de la función con base radial demostró un rendimiento óptimo con respecto a la predicción de fuerza de tiro; y los parámetros clave correspondientes a dicho modelo óptimo asumen los siguientes valores: $C = 1604.774$, $\varepsilon = 0.001$, $\lambda = 0.123$, y $p = 0.012$. El tiempo total de la corrida del análisis fue de 3.93 min. La raíz del error cuadrático medio en las predicciones realizadas por el modelo propuesto fue de 0.288 kN, y el coeficiente de correlación entre las fuerzas de tiro reales y previstas fue de 0.969, lo que confirma un rendimiento satisfactorio del modelo propuesto.

* Author for correspondence ♦ Autor responsable.

Received: May, 2018. Approved: August, 2019.

Published as ARTICLE in *Agrociencia* 53: 1257-1273. 2019.

Key words: tillage, moldboard plow, draft force, support vector regression, learning algorithms.

INTRODUCTION

The moldboard plow is an important tillage implement employed in soil-tillage applications (Formato *et al.*, 2005), and it is utilized in such applications as seedbed preparation in the least possible time by accomplishing the maximum field capacity of tillage implements (Sahu and Raheman, 2006). However, draft requirements of a moldboard plow greatly depend on the plow-body geometry as well as soil properties, such as moisture content, bulk density, soil friction, and adhesion (Godwin *et al.*, 2007). Moreover, operating factors, such as plowing depth and plowing speed, also affect draft requirements of a moldboard plow (Naderloo *et al.*, 2009; Rashidi *et al.*, 2013a and 2013b; Al-Suhaibani *et al.*, 2015). Due to an increased importance of the draft in determining the fuel consumption and required tractor power (Arvidsson and Hillerstrom, 2010) as well as selection of a suitable tractor (KarimiInchebron *et al.*, 2012), many extant studies were performed to provide a means to evaluate factors affecting the draft force acting on a moldboard plow.

Given the present competitive and dynamic farm-mechanization-management environment, predictions of accurate draft requirements of tillage implements are challenging. The draft force acting on a moldboard plow plays an important role in the design of more efficient plows to facilitate attainment of optimum results when implementing size matching to estimate the required tractor power. Unfortunately, accurate collection of draft-force data under various field conditions is an expensive and time-consuming exercise. Thus, prediction of draft-force acting on a moldboard plow is of great importance regarding farm-management patterns.

Establishment of a linear regression model based on a small data set for accurate prediction of the draft force of tillage implements is the dominant method employed within statistical approaches (Ranjbar *et al.*, 2013; Wandkar *et al.*, 2013; Al-Suhaibani *et al.*, 2015). However, data over-fitting is a problem encountered when using the regression-model approach. Recent advances in artificial intelligence and soft-computing techniques have replaced

Palabras clave: labranza, arado de vertederas, fuerza de tiro, vectores soporte para regresión, algoritmos de aprendizaje.

INTRODUCCIÓN

El arado de vertedera es una importante herramienta de labranza empleada en aplicaciones de labranza del suelo (Formato *et al.*, 2005), tales como la preparación de semilleros en el menor tiempo posible, con la capacidad de campo máxima de herramientas de labranza (Sahu y Raheman, 2006). Sin embargo, los requisitos de tiro de un arado de vertederas dependen en gran medida de la geometría del cuerpo del arado, así como de las propiedades del suelo, como el contenido de humedad, la densidad aparente, la fricción del suelo y la adhesión (Godwin *et al.*, 2007). Además, los factores operativos, tales como la profundidad y la velocidad de arado, también afectan los requisitos de tiro de un arado de vertederas (Naderloo *et al.*, 2009; Rashidi *et al.*, 2013a y 2013b; Al-Suhaibani *et al.*, 2015). Debido a la creciente importancia del tiro para determinar el consumo de combustible y la potencia requerida del tractor (Arvidsson y Hillerstrom, 2010), así como la selección de un tractor adecuado (KarimiInchebron *et al.*, 2012), existen muchos estudios previos sobre los medios para evaluar los factores que afectan a la fuerza de tiro del arado de vertederas.

Dado el entorno competitivo y dinámico de gestión de la mecanización agrícola, las predicciones de los requerimientos precisos de la fuerza de tiro en herramientas de labranza son un desafío. La fuerza de tiro que actúa sobre un arado de vertederas juega un papel importante en el diseño de arados más eficientes para la obtención de resultados óptimos al implementar la coincidencia del tamaño para estimar la potencia requerida del tractor. La desventaja es que, la recopilación precisa de datos sobre la fuerza de tiro bajo diversas condiciones de campo es un ejercicio costoso y que requiere mucho tiempo. Por lo tanto, la predicción de la fuerza de tiro que actúa sobre un arado de vertederas es de gran importancia para gestionar el manejo agrícola.

El establecimiento de un modelo de regresión lineal basado en un pequeño conjunto de datos para la predicción precisa de la fuerza de tiro de las herramientas de labranza es el método dominante empleado dentro de los enfoques estadísticos (Ranjbar *et al.*, 2013; Wandkar *et al.*, 2013; Al-Suhaibani *et al.*,

traditional mathematical functions employed in big data analyses and other complex processes.

Soft computing is a set of computing techniques, such as fuzzy logic, artificial neural networks, and genetic algorithms. These computing techniques, unlike hard computing which refers to a huge set of conventional techniques, such as stochastic and statistical methods; offer somewhat “inexact” solutions of very complex problems through problem modeling and subsequent analysis with a certain tolerance of imprecision, uncertainty, partial truth, and approximation (Huang *et al.*, 2010; Abbaspour-Gilandeh and Sedghi, 2015). Rahman *et al.* (2011) developed a neural-network model to predict the energy requirement of a tillage tool based on laboratory data. Roul *et al.* (2009) applied a 5–9–1 artificial neural network (ANN) model with a backpropagation learning algorithm to predict draft requirements for different tillage implements to be used on sandy clay loam soil. Mohammadi *et al.* (2012) proposed a fuzzy inference system model through use of the Mamdani min–max method and 24 rules based on a table look-up scheme in order to predict draft-force requirements of two-winged share tillage tools used on loam soils under varying operating conditions. Abbaspour–Gilandeh and Sedghi (2013) developed a knowledge-based fuzzy logic system using experimental data and used it to predict draft force and energy requirements of tillage operations. Shafaei *et al.* (2017) utilized the Takagi–Sugeno–Kang-type adaptive neuro–fuzzy inference system for draft-force prediction of a chisel plow implement.

Support vector machine (SVM) algorithms have gained popularity compared to other soft-computing techniques, such as artificial neural networks. Though artificial neural networks are popular owing to their ease of implementation, they suffer a major drawback, which prevents them from being considered as efficient algorithms (Thomas *et al.*, 2017). Artificial neural networks are based on the principle of empirical risk minimization, and hence, the best ANN architecture is the one that suffers minimum training error. This results in the two major issues of over fitting and local minima. ANN also suffers an overhead, since its computational complexities are dependent upon dimensions of the input space.

In the absence of all the afore mentioned drawbacks, use of the SVM system provides global,

2015). Sin embargo, el sobreajuste de los datos es un problema que se presenta cuando se utiliza el enfoque del modelo de regresión. Los recientes avances en inteligencia artificial y técnicas de soft computing han reemplazado las funciones matemáticas tradicionales empleadas en grandes análisis de datos y otros procesos complejos.

El soft-computing (cómputo flexible) es un conjunto de técnicas informáticas, tales como la lógica difusa, las redes neuronales artificiales y los algoritmos genéticos. Estas técnicas informáticas, a diferencia del hard-computing (cómputo restringido) el cual refiere a un conjunto enorme de técnicas convencionales como los métodos estocásticos y estadísticos, ofrecen soluciones un tanto “inexactas” a problemas muy complejos a través de la modelarlos y realizar un análisis posterior con una cierta tolerancia a la imprecisión, la incertidumbre, la verdad parcial y la aproximación (Huang *et al.*, 2010; Abbaspour-Gilandeh y Sedghi, 2015). Rahman *et al.* (2011) desarrollaron un modelo de red neuronal para predecir el requerimiento de energía de una herramienta de labranza basada en datos de laboratorio. Roul *et al.* (2009) aplicaron un modelo de red neural artificial (ANN) 5-9-1 con un algoritmo de aprendizaje de retropropagación para predecir los requisitos de tiro para las diferentes herramientas de labranza utilizadas en suelos franco arcillo arenosos. Mohammadi *et al.* (2012) propusieron un modelo de sistema de inferencia difusa mediante el uso del método Mamdani min-max, y 24 reglas basadas en un esquema de búsqueda tabular con el fin de predecir los requisitos de fuerza de tiro de las herramientas de labranza con soportes de dos alas utilizadas en suelos limosos bajo condiciones de operación variables. Abbaspour-Gilandeh y Sedghi (2013) desarrollaron un sistema de lógica difusa basado en el conocimiento con datos experimentales y lo utilizaron para predecir los requerimientos de fuerza de tiro y energía en operaciones de labranza. Shafaei *et al.* (2017) utilizaron el sistema de inferencia neuro-difuso adaptable tipo Takagi-Sugeno-Kang para la predicción de la fuerza de tiro de una herramienta de arado de cincel.

Los algoritmos de máquinas vectoriales de soporte (SVM) han ganado popularidad en comparación con otras técnicas de soft computing, como las redes neuronales artificiales. Aunque las redes neuronales artificiales son populares debido a su facilidad de implementación, sufren un gran inconveniente, el cual les impide ser consideradas como algoritmos eficientes

unique, and sparse solution to complex problems (Thomas *et al.*, 2017). It is also less prone to the problem of over fitting as it works on the principle of structural risk minimization. Support vector regression originates from the SVM principle, which was originally developed to solve classification and pattern-recognition problems and success fully extended to solve forecasting problems in numerous fields (Chu *et al.*, 2016). The support vector regression (SVR) architecture is, therefore, applied to almost all domains, and prior studies have demonstrated that SVR techniques result in good generalization in different applications (Chu *et al.*, 2016; Khan and Coulibaly, 2006).

Regarding agricultural and biological engineering applications, researchers and engineers have developed methods based on fuzzy logic and artificial neural networks (Choi *et al.*, 2000; Al-Janobi *et al.*, 2001; Alimardani *et al.*, 2009) to predict the draft force acting on tillage implements through consideration of different parameters. However, draft-force prediction using SVM technique is not yet reported in literature. The growing interest in reliable draft-force prediction as a basis for planning and control of agricultural activities requires interdisciplinary cooperation with active involvement of domain experts, e.g. those having an agricultural research background.

The aim of this study, therefore, was to investigate the relevance of state-of-the-art machine-learning techniques, such as ϵ -SVR and ν -SVR, in predicting the draft force acting on the moldboard plow whilst considering plowing speed, plowing depth, and soil moisture content as governing parameters. Moreover, a performance comparison with respect to prediction capabilities of support vector regression, multiple linear regression, and the developed analytical moldboard plow draft-force prediction spreadsheet was performed. All models employed in this study were designed to estimate the relationship between draft force of a moldboard plow and plowing speed, plowing depth, and soil moisture content, thereby serving to identify the most important parameter in terms of farm machinery management. Objectives were: 1) identification of the best model-parameter settings using grid- and pattern-search techniques, and 2) comparison of prediction accuracy obtained using different models via cross-validation.

(Thomas *et al.*, 2017). Las redes neuronales artificiales se basan en el principio de la minimización empírica del riesgo, y por lo tanto, la mejor arquitectura de la ANN es la que experimenta un error de entrenamiento mínimo. Esto resulta en los dos problemas principales, sobreajuste y mínimos locales. La ANN también sufre una sobrecarga, ya que sus complejidades computacionales dependen de las dimensiones del espacio de entrada.

En ausencia de todos los inconvenientes mencionados anteriormente, el uso del sistema SVM proporciona una solución global, única y dispersa a problemas complejos (Thomas *et al.*, 2017). También es menos propenso al problema del sobreajuste, ya que funciona según el principio de minimización del riesgo estructural. Los vectores de soporte para regresión se originan a partir del principio SVM, el cual se desarrolló originalmente para resolver problemas de clasificación y reconocimiento de patrones, y cuyo éxito se extendió al máximo para resolver problemas de pronóstico en numerosos campos (Chu *et al.*, 2016). La arquitectura del vector soporte para regresión (SVR) se aplica, por lo tanto, a casi todos los dominios, y estudios previos han demostrado que las técnicas de SVR dan como resultado una generalización apropiada para aplicaciones diferentes (Chu *et al.*, 2016; Khan y Coulibaly, 2006).

En cuanto a las aplicaciones de ingeniería agrícola y biológica, los investigadores e ingenieros han desarrollado métodos basados en la lógica difusa y en redes neuronales artificiales (Choi *et al.*, 2000; Al-Janobi *et al.*, 2001; Alimardani *et al.*, 2009) para predecir la fuerza de tiro que actúa sobre las herramientas de labranza con la consideración de parámetros diferentes. Sin embargo, la predicción de la fuerza de tiro con la técnica de SVM todavía no consta en la literatura. El interés creciente en la predicción confiable de la fuerza de tiro como base para la planificación y el control de las actividades agrícolas requiere una cooperación interdisciplinaria con la participación activa de expertos en la materia, por ejemplo, aquellos que tienen experiencia en investigación agrícola.

En consecuencia, el objetivo de este estudio fue investigar la relevancia de las técnicas más avanzadas de aprendizaje computarizado, tales como ϵ -SVR y ν -SVR, para predecir la fuerza de tiro que actúa sobre el arado de vertederas, al tomar en cuenta la velocidad de arado, la profundidad de arado y el contenido de

MATERIALS AND METHODS

Experimental site

All experiments were performed at the experimental farm in the College of Food and Agriculture Sciences, King Saud University, Saudi Arabia. Coordinates of the experimental site are 24° 43' N and 46° 43' E at an elevation of 635 m above mean sea level. The experimental field was void of any agricultural activity. Prior to performing the tillage experiment, the field was irrigated for 3 h by means of sprinklers. Soil samples from 12 points at the experimental site were collected at varying depths, in the range of 0-30 cm, and analyzed for particle size distribution (concerning sand, silt, and clay) in the laboratory. Soil from the field was classified by means of mechanical analysis, and soil samples were collected using an auger to determine soil bulk density and moisture content. Collected soil samples were weighed using a balance scale, and the weight of each sample was recorded. Subsequently, the samples were placed in an electric oven and maintained at 110 °C for 48 h. The dried soil samples were then reweighed, and the weight was, once again, recorded. Soil moisture content was evaluated, albeit on the dry-weight basis (db). Soil at the experimental site was classified as sandy-loam type, based on its features in the above analysis; particle-size distribution was characterized at two depths (Table 1) and average bulk density, measured (1.57 g cm⁻³).

A randomized complete block design with two replicates was employed to evaluate the effect of soil moisture content, plowing depth, and plowing speed on the draft force acting of the moldboard plow. Three values each of the soil moisture content 9.9, 10.9, and 13.2% db, plowing speed 2.71, 3.21, and 4.32 km h⁻¹, and plowing depth 9, 14, and 16 cm were defined, thereby resulting in 27 different operating conditions or treatments. Treatments were performed at randomly distributed locations within the experimental field.

Field-test procedure

A two-furrow-mounted moldboard plow measuring 36 cm in width was used in this study. The used moldboard plow was

Table 1. Particle-size distribution of the soil at the experimental site.

Cuadro 1. Distribución granulométrica del suelo en el sitio experimental.

Soil depth (cm)	Sand (%)	Silt (%)	Clay (%)
0-20	74.81	11.77	13.42
20-30	72.64	11.65	15.71

humedad del suelo como parámetros determinantes. Además, se realizó una comparación de rendimiento con respecto a las capacidades de predicción de los vectores soporte para regresión, la regresión lineal múltiple y la hoja de cálculo analítica disponible para la predicción de la fuerza de tiro del arado de vertederas. Todos los modelos empleados en este estudio se diseñaron para estimar la relación entre la fuerza de tiro de un arado de vertederas y la velocidad de arado, la profundidad de arado y el contenido de humedad del suelo; para identificar entre ellos el parámetro más importante en términos del manejo de maquinaria agrícola. Los objetivos fueron: 1) identificar los mejores ajustes de los parámetros del modelo mediante técnicas de búsqueda por cuadrícula y por patrón, y 2) comparar la precisión de la predicción obtenida con los diferentes modelos, a través de validación cruzada.

MATERIALES Y MÉTODOS

Sitio experimental

Todos los experimentos se realizaron en la granja experimental de la Facultad de Ciencias Agrícolas y Alimentarias de la Universidad Rey Saudí, en Arabia Saudita. Las coordenadas del sitio experimental son 24° 43' N y 46° 43' E en 635 m de altitud sobre el nivel medio del mar. El campo experimental carente de toda actividad agrícola. Antes de realizar el experimento de labranza, el campo se regó durante 3 horas por medio de aspersores. Muestras de suelo se recolectaron en 12 puntos del sitio experimental a diferentes profundidades, en el intervalo de 0-30 cm y se analizaron en el laboratorio para determinar la distribución granulométrica (la relación entre arena, limo y arcilla). El suelo del campo se clasificó por medio de análisis mecánicos, y las muestras de suelo se recolectaron utilizando una barrena para determinar la densidad aparente y el contenido de humedad del suelo. Las muestras de suelo recolectadas se pesaron con una balanza y se registró el peso de cada muestra. Después, las muestras se colocaron en un horno eléctrico y se mantuvieron a 110 °C durante 48 h. A continuación, las muestras de suelo seco se volvieron a pesar y se registró otra vez el peso. Así se evaluó el contenido de humedad del suelo, como porcentaje con base en la masa seca del material (bs). El suelo en el sitio experimental se clasificó como franco-arenoso, con base en las características registradas en el análisis anterior; la distribución granulométrica se caracterizó en dos profundidades (Cuadro 1) y se midió su densidad aparente promedio (1.57 g cm⁻³).

Un diseño de bloques completos al azar con dos repeticiones se usó para evaluar el efecto del contenido de humedad del

of the general-purpose type (specifications are listed in Table 2) and was hitched onto the 3-point linkage of a tractor. This configuration is representative of the standard primary tillage implement commonly used for tillage in Saudi Arabia.

Plowing operations were performed on experimental blocks of land measuring 50×3 m. A small block, approximately 10×3 m, was used at the beginning of each tested block to facilitate the tractor and plow to attain a steady plowing state corresponding to the required plowing speed and depth. The plowing depth was measured as the vertical distance from the top of the undisturbed soil surface to the deepest penetration of the plow. The draft force (horizontal force) acting on the plow was measured using a calibrated load cell (Omega) with a load capacity up to 10 000 lb (44.5 kN) using the method described in PAES (2001).

The moldboard plow was hitched onto a John Deere 1030 tractor; besides, an auxiliary tractor—Massey Ferguson 440—was used in this study. The draft was recorded within 40 m and the plowing speed was calculated by measuring the distance covered by the rear wheel of the tractor in five turns divided by the time required for the same. On the same field, the plow was lifted above the ground, and the rear part of the tractor was pulled to record the idle draft force. The difference between the draft force earlier recorded and the idle draft force yielded an estimate of the draft force of the plow. Different plowing speeds were obtained by changing tractor gears.

During field operation, the tractor lowered the implement to the corresponding tillage depth. The tractor was then accelerated to the required plowing speed within a known gear range prior to entering the first test block. The draft-data readout device connected to the tractor battery was activated, by means of a dip switch located on the activity unit, as the tractor crossed the flag that marked the beginning of the first test block. Readings were manually recorded until the tractor reached the end of the test block. After finishing the plowing operation at a given test block, the tractor was directly driven to the next test block at a different plowing speed, and the above plowing process was repeated. A

suelo, la profundidad de arado y la velocidad de arado sobre la fuerza de tiro que actúa en el arado de vertederas. Tres valores de humedad del suelo se definieron 9.9, 10.9 y 13.2% bs, velocidad de arado de 2.71, 3.21 y 4.32 km h⁻¹ y profundidad de arado de 9, 14 y 16 cm, lo que dio como resultado 27 condiciones de funcionamiento o tratamientos diferentes. Los tratamientos se realizaron en lugares distribuidos aleatoriamente dentro del campo experimental.

Procedimiento de prueba de campo

En este estudio se utilizó un arado de vertederas de dos surcos de 36 cm de ancho. El arado de vertederas usado era del tipo de uso general (las especificaciones se enumeran en el Cuadro 2) y se enganchó en el acoplamiento de 3 puntos de un tractor. Esta configuración es representativa de la herramienta de labranza primaria estándar de uso común para la labranza en Arabia Saudita.

Las operaciones de arado se realizaron en bloques de terreno experimentales de 50×3 m. Al principio de cada bloque de prueba se utilizó un bloque pequeño, de aproximadamente 10×3 m, para facilitar que el tractor y el arado alcanzaran un estado de arado firme correspondiente a la velocidad y profundidad de arado requeridas. La profundidad de arado se midió como la distancia vertical desde la parte superior no perturbada de la superficie del suelo hasta la penetración más profunda del arado. La fuerza de tiro (fuerza horizontal) que actúa sobre el arado se midió con una celda de carga calibrada (Omega) con capacidad de carga de hasta 44.5 kN (10 000 lb) y con el uso del método descrito en PAES (2001).

El arado de vertederas se enganchó a un tractor John Deere 1030; además, en este estudio se utilizó un tractor auxiliar (Massey Ferguson 440). El tiro se registró dentro de 40 m y la velocidad de arado se calculó midiendo la distancia recorrida por la rueda trasera del tractor en cinco vueltas dividida por el tiempo requerido para las mismas. En el mismo campo, el arado se levantó por encima del suelo y se tiró de la parte trasera del tractor para registrar la fuerza de tiro inactiva. La diferencia entre la fuerza de tiro registrada anteriormente y la fuerza de tiro inactiva dio como resultado una estimación de la fuerza de tiro del arado. Diferentes velocidades de arado se obtuvieron cambiando las marchas del tractor.

Durante la operación de campo, el tractor bajaba la herramienta de labranza a la profundidad de labranza correspondiente. A continuación, el tractor se aceleraba hasta alcanzar la velocidad de arado necesaria dentro de un intervalo de cambio de marchas establecido antes de entrar al primer bloque de prueba. El dispositivo de lectura de los datos de tiro, conectado a la batería del tractor, se activó mediante un interruptor DIP situado en la unidad de actividad, cuando el tractor cruzó la bandera que marcaba el comienzo del primer bloque de prueba. Las lecturas

Table 2. Specifications of used moldboard plow.

Cuadro 2. Especificaciones del arado de vertederas utilizado.

Items	Value
Share sweep angle, β (°)	44
Moldboard tail angle, θ (°)	39
Point depth (cm)	6
Point width (cm)	7
Rake angle, α (°)	23
Share width (cm)	36
Moldboard length (cm)	87

similar procedure was repeated for other operating conditions as well. Data collected were subjected to ANOVA using SPSS 19 statistical computer software and treatment means were compared with the Tukey test ($p \leq 0.05$).

Available draft spreadsheet to enable draft-force calculations

Ahmadi (2016) developed an Excel spreadsheet to enable draft-force calculations by supplying soil parameters (soil cohesion, angle of soil-soil internal friction, soil-metal friction angle and soil bulk density), plow parameters (moldboard tail angle and working width of the plow), and working condition parameters (plowing speed and working depth), as inputs. Also, the help of equations related to determine soil parameters were provided in Aboukarima (2012). For the soil moisture content range, soil cohesion values were 16.440, 16.459, and 16.503 kPa, values of angle of soil-soil internal friction were 35.591, 35.160 and 34.168 degrees and values of soil-metal friction angles were 20.418, 20.171 and 9.602 degrees.

Multiple regression model

A multiple regression model was developed in order to further investigate the relationship between independent (predictor) variables and a dependent variable. The general form of a regression equation is given by

$$Y = b_0 + b_1 X_1 + \dots + b_3 X_3 \quad (1)$$

where: Y, the dependent variable representing the draft force; b_0 , the ordinate at which the regression line intercepts y-axis; $b_0 \dots b_3$, regression coefficients representing the amount of change in the dependent variable Y when corresponding predictor variables undergo unit change; $X_1 - X_3$, independent variables corresponding to the plowing depth, plowing speed, and soil moisture content.

Support Vector Machine (SVM)

Support vector machine (SVM) is a powerful machine learning technique for classification and regression. It is based on statistical learning theory (Woodsend and Gondzio, 2009). The problem is solved by modeling it as a quadratic programming problem comprising an inequality constraint. When SVM is employed to solve a regression problem, it is termed as an SVR. The SVR algorithm can be explained as follows (Thomas *et al.*, 2017).

Consider a given set of training data $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, where $x_i \in R^d$, $y_i \in R$; $i = 1$. Training data x_i from an input

se registraron manualmente hasta que el tractor llegó al final del bloque de prueba. Después de terminar la operación de arado en un bloque de prueba dado, el tractor se condujo directamente al siguiente bloque de prueba a una velocidad de arado diferente, y se repitió el proceso de arado anterior. Un procedimiento similar se repitió también para otras condiciones de funcionamiento. Los datos registrados se sometieron a ANDEVA con el programa de cómputo estadístico SPSS 19, y las medias de tratamiento se compararon con la prueba de Tukey ($p \leq 0.05$).

Hoja de cálculo disponible para el cálculo de la fuerza de tiro

Ahmadi (2016) desarrolló una hoja de cálculo en Excel para permitir el cálculo de la fuerza de tiro, al ingresar datos de parámetros de suelo (cohesión del suelo, ángulo de fricción interna suelo-suelo, ángulo de fricción suelo-metal y densidad aparente del suelo), parámetros de arado (ángulo de la cola de la vertedera y anchura operativa del arado), y condiciones de trabajo (velocidad de arado y profundidad operativa), como información de entrada. También, Aboukarima (2012) aportó las ecuaciones relacionadas con la determinación de los parámetros del suelo. Para el intervalo de contenido de humedad del suelo, los valores de cohesión del suelo fueron 16.440, 16.459 y 16.503 kPa, los valores de ángulo de fricción interna suelo-suelo fueron 35.591, 35.160 y 34.168 grados y los valores de ángulos de fricción suelo-metal fueron 20.418, 20.171 y 9.602 grados.

Modelo de regresión múltiple

Un modelo de regresión múltiple se desarrolló para investigar más a fondo la relación entre las variables independientes (predictoras) y una variable dependiente. La forma general de una ecuación de regresión se da por

$$Y = b_0 + b_1 X_1 + \dots + b_3 X_3 \quad (1)$$

donde: Y, es la variable dependiente que representa la fuerza de tiro (tracción); b_0 , es la ordenada en la cual la línea de regresión intercepta el eje y; $b_0 \dots b_3$, son los coeficientes de regresión que representan la cantidad de cambio en la variable dependiente Y cuando las variables predictoras correspondientes cambian de unidad; $X_1 - X_3$, son las variables independientes que corresponden a la profundidad de arado, velocidad de arado y contenido de humedad del suelo.

Mecanismo de vectores soporte (SVM)

El mecanismo de vectores de soporte (SVM) es una técnica potente de aprendizaje computarizado para clasificación y regresión;

space X are mapped onto a feature space Q as θ (i.e., $x_i \rightarrow \theta(x_i)$) using a predefined nonlinear function $\mathcal{G}(x)$. Let f represent the linear function that takes the following form.

$$f(x) = w^T x + b = \langle w, x \rangle + b, \text{ where } w \in X, b \in R, \langle \cdot, \cdot \rangle \quad (2)$$

Numerical simulations

All simulations reported in this study were performed using DTREG, a predictive modeling software that is capable of building classification and regression models that describe data relationships and can be used to predict values for future observations (Sherrod, 2003), and it facilitates the use of data-mining techniques. In-line with the objectives of the proposed study, ε -SVR and ν -SVR models were employed to predict the draft-force acting on the moldboard plow wherein, the grid- and pattern-search techniques were used to determine optimum values of the parameters involved in the two SVR models. Kernel functions supported by DTREG as well as their characteristic relations (Sherrod, 2003) are listed below:

Linear Kernel:

$$k(x_p, x_j) = x_p^T * x_j \quad (3)$$

Sigmoid Kernel:

$$k(x_p, x_j) = \tanh(\text{gamma} * x_p^T * x_j + \text{coef}0) \quad (4)$$

Radial Basis Function Kernel:

$$k(x_p, x_j) = \exp(-\text{gamma} * \|x_i - x_j\|^2) \quad (5)$$

Polynomial Kernel:

$$k(x_p, x_j) = \text{gamma} * x_p^T * x_j + \text{coef}0)^{\text{degree}} \quad (6)$$

Accuracies of SVR models are largely dependent on the appropriate selection of kernel parameters— C , γ , P . The grid search determines value of C , γ , P , across a specified search range using geometric steps. Pattern search (also known as “compass search” or a “line search”), starts from the center of the range of parametric values and performs trial steps along the forward as well as backward directions to determine appropriate values for each parameter. If an improvement in model fit is observed, the search center moves onto a new point, and the process is

se basa en la teoría del aprendizaje estadístico (Woodsend y Gondzio, 2009). El problema se resuelve al modelarlo como un problema de programación cuadrática que incluye una restricción de desigualdad. Cuando el SVM se usa para resolver un problema de regresión, se denomina SVR. El algoritmo SVR puede explicarse de la siguiente manera (Thomas *et al.*, 2017).

Considere un conjunto dado de datos de entrenamiento $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, donde $x_i \in R^d, y_i \in R; i = 1$. Los datos de entrenamiento x_i de un espacio de entrada X se asignan a un espacio de característica Q como θ (i.e., $x_i \rightarrow \theta(x_i)$) a través de una función no lineal predefinida $\mathcal{G}(x)$. Sea f la representación de la función lineal que toma la forma siguiente:

$$f(x) = w^T x + b = \langle w, x \rangle + b, \text{ where } w \in X, b \in R, \langle \cdot, \cdot \rangle \quad (2)$$

Simulaciones numéricas

Todas las simulaciones registradas en este estudio se realizaron con DTREG, un software de modelación predictiva que es capaz de construir modelos de clasificación y regresión para describir relaciones entre datos, que puede usarse para predecir valores para observaciones futuras (Sherrod, 2003), y facilita el uso de técnicas de exploración profunda de datos. De acuerdo con los objetivos del estudio propuesto, se emplearon los modelos ε -SVR y ν -SVR para predecir la fuerza de tiro que actúa sobre el arado de vertederas, para lo cual se utilizaron las técnicas de búsqueda por cuadrícula y por patrón para determinar los valores óptimos de los parámetros implicados en los dos modelos SVR. Las funciones de núcleo soportadas por el DTREG, así como sus relaciones características (Sherrod, 2003) fueron como se muestra a continuación:

Núcleo lineal:

$$k(x_p, x_j) = x_p^T * x_j \quad (3)$$

Núcleo sigmoide:

$$k(x_p, x_j) = \tanh(\text{gamma} * x_p^T * x_j + \text{coef}0) \quad (4)$$

Núcleo de función de base radial:

$$k(x_p, x_j) = \exp(-\text{gamma} * \|x_i - x_j\|^2) \quad (5)$$

Núcleo polinómico:

$$k(x_p, x_j) = \text{gamma} * x_p^T * x_j + \text{coef}0)^{\text{degree}} \quad (6)$$

repeated. If no such improvement is observed, the step size is reduced, and the search is repeated. The pattern search stops when the size of search steps is reduced to a specified tolerance level. In order to avoid any instance of over fitting, cross-validation is performed to evaluate the fitting provided by each set of parameter values tested during the grid or pattern search processes (Sherrod, 2003).

The value of parameter C was first randomly specified as input, and was observed to influence the value of the approximation error and weight vector norm w . At instances of large errors, the value of the parameter C was increased. Another design parameter, the choice of the value of which is easier to make as compared to C , is the desired precision embodied in the value of ε (Sherrod, 2003). The grid-search technique seeks values of each parameter through use of the minimized total error. Model parameters, such as upper bound C , kernel parameter γ , and P that lie within search ranges of 0.1–5000, 0.001–50, and 0.0001–100, respectively, along with unit polynomial degree—for the purpose of analysis—and ν lying in the range of 0.001–0.6 were considered in this study (Sherrod, 2003). Once parameter values are specified, a reliable draft-force prediction model with high stability could be built by means of employing the pattern-search technique involving 10 search intervals, which would require 1000 model evaluations, and setting 10^{-8} as the tolerance level to be achieved for terminating the iterative optimization process.

Values of model parameters significantly impact model accuracy. If one chooses to perform cross-validation for each model evaluation, the total number of actual calculations required would be further multiplied by the number of cross-validation steps (10 for the current experiment setup). No missing values were handled, and all rows were used when performing the parameter-value search. The goal here was to minimize the total error. For the purpose of model testing and validation, 10 cross-validation steps were used. Other miscellaneous controls used include the following:

- 1) Shrinking heuristics, which serves to improve model performance when handling large training datasets by ignoring points possessing a lower tendency to overlap and which are unlikely to influence the choice of the optimum separating hyper plane (Thomas *et al.*, 2017). Shrinking, therefore, eliminates the consideration of outlying vectors.
- 2) Cache memory occupying a default space of 256 MB to store truncated rows of the recorded kernel matrix. Availability of a cache avoids re-computation of components of the kernel matrix, and in some cases, it also tends to speed up the computation by a significant amount. Variable importance is calculated by generating a report that demonstrates the relative significance of

Las precisiones de los modelos SVR dependen en gran medida de la selección apropiada de los parámetros de núcleo (funciones kernel) C , γ , P . La búsqueda por cuadrícula determina el valor de C , γ , P , a través de una amplitud de búsqueda especificada por pasos geométricos. La búsqueda por patrón (conocida también como “búsqueda de brújula” o “búsqueda en líneas”), comienza en el centro de la amplitud de valores paramétricos y realiza pasos de prueba a lo largo de las direcciones hacia adelante y hacia atrás para determinar los valores apropiados para cada parámetro. Si se observa una mejora en el ajuste del modelo, el centro de búsqueda se desplaza a un nuevo punto y el proceso se repite. Si no se observa tal mejora, se reduce el tamaño del paso y se repite la búsqueda. La búsqueda de patrones se detiene cuando el tamaño de los pasos de búsqueda se reduce a un nivel de tolerancia especificado. Para evitar cualquier caso de sobreajuste, se realiza una validación cruzada para evaluar el ajuste proporcionado por cada conjunto de valores de parámetros probados durante los procesos de búsqueda por cuadrícula o patrón (Sherrod, 2003).

El valor del parámetro C se especificó primero aleatoriamente como entrada, y se observó que influía en el valor del error de aproximación y en la norma w del vector de ponderación. En casos de errores grandes, el valor del parámetro C se incrementó. Otro parámetro de diseño, cuya elección del valor es más fácil de hacer en comparación con C , es la precisión deseada que se refleja en el valor de ε (Sherrod, 2003). La técnica de búsqueda por cuadrícula busca valores de cada parámetro mediante el uso del error total minimizado. En este estudio se consideraron parámetros del modelo, tales como el límite superior C , el parámetro del núcleo γ y P , los cuales se encontraban dentro de las amplitudes de búsqueda de 0.1-5000, 0.001-50 y 0.0001-100, respectivamente, junto con el grado unitario del polinomio para su análisis, y ν que se encontraba dentro de la amplitud de 0.001-0.6 (Sherrod, 2003). Una vez especificados los valores de los parámetros, se podría construir un modelo confiable de predicción de fuerza de tiro con estabilidad alta mediante el empleo de la técnica de búsqueda por patrón que incluye 10 intervalos de búsqueda, lo cual requeriría 1000 evaluaciones de modelos, y se estableció en 10^{-8} el nivel de tolerancia que debía alcanzarse para finalizar el proceso de optimización iterativa.

Los valores de los parámetros del modelo tienen un impacto significativo en la precisión del modelo. Si se opta por realizar una validación cruzada para cada evaluación de modelo, el número total de cálculos reales necesarios se multiplicaría por el número de pasos de validación cruzada (10 para la configuración del presente experimento). No se permitieron valores faltantes y se utilizaron todas las filas al realizar la búsqueda de valor-parámetro. El objetivo fue minimizar el error total. Con el fin de probar y validar el modelo, se utilizaron 10 pasos de validación cruzada. Otros controles misceláneos utilizados fueron los siguientes:

predictor variables. The error involved during each prediction is given by the difference between the actual and predicted areas.

Validation of model performance

The fitness value is a good indicator of the error incurred in the sense that the smaller the error, the higher is the fitness value. The DTREG software calculates the maximum error, root-mean squared error (RMSE), mean squared error (MSE), mean absolute error (MAE), and the mean absolute percentage error (MAPE) as different measures of fitness. Moreover, the correlation coefficient can also be considered an indicator of fitness. MAPE is generally considered as a more objective statistic indicator because it is determined in terms of the relative percentage and is not affected by units of the concerned variable. Formulae to evaluate RMSE, MSE, MAE, and MAPE are listed in Table 3, where *Odraft* denotes the observed draft force (kN) while *Pdraft* denotes the predicted draft force (kN), and *n* denotes number of patterns.

RESULTS AND DISCUSSION

Statistical analysis

Results obtained via ANOVA on the effects of input parameters on output parameter variation are presented in Table 4. They demonstrate that plowing speed, plowing depth, and soil moisture content significantly ($p \leq 0.05$) affect the draft force acting on the moldboard plow. Greater plowing depths result in generation of a larger reaction force exerted by the

1) La heurística de reducción, que sirve para mejorar el rendimiento del modelo cuando se manejan grandes conjuntos de datos de entrenamiento, por medio de ignorar los puntos que tienen una tendencia menor a superponerse, los cuales es poco probable que influyan en la elección del hiperplano de separación óptimo (Thomas *et al.*, 2017). Por lo tanto, la reducción elimina la consideración de vectores periféricos.

2) La memoria caché, que ocupa un espacio por omisión de 256 MB para almacenar filas truncadas de la matriz de núcleos registrada. La disponibilidad de una caché evita tener que recalcular los componentes de la matriz de núcleos y, en algunos casos, también tiende a acelerar el cálculo en magnitud significativa. La importancia de las variables se calcula con la generación de un informe que demuestra la importancia relativa de las variables predictoras. El error en cada predicción se da por la diferencia entre las áreas reales y las pronosticadas.

Validación del desempeño del modelo

El valor de adecuación es un buen indicador del error incurrido, en el sentido de que cuanto menor sea el error, mayor será el valor de adecuación. El software DTREG calcula el error máximo, la raíz del del error cuadrático medio (RMSE), el error cuadrático medio (MSE), el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE) como diferentes medidas de adecuación. Además, el coeficiente de correlación también puede considerarse un indicador de adecuación. El MAPE en general se considera como un indicador estadístico más objetivo porque se determina en términos del porcentaje relativo y no se ve afectado por las unidades de la variable en cuestión. Las fórmulas para evaluar RMSE, MSE, MAE y MAPE se enumeran

Table 3. Formulae for calculating RMSE, MSE, MAE, and MAPE.

Cuadro 3. Cuadro 3. Fórmulas para calcular RMSE, MSE, MAE, y MAPE.

Criteria	Description	Formula
MAE	Mean Absolute Error	$MAE = \frac{\sum_{i=1}^n Odraft_i - Pdraft_i }{n}$
MAPE	Mean Absolute Percentage Error	$MAPE = \frac{1}{n} * \sum_{i=1}^n \left(\frac{Odraft_i - Pdraft_i}{Odraft_i} \right) * 100$
MSE	Mean Squared Error	$MSE = \frac{1}{n} * \sum_{i=1}^n (Odraft_i - Pdraft_i)^2$
RMSE	Root Mean Squared Error	$RMSE = \frac{1}{n} * \sqrt{\sum_{i=1}^n (Odraft_i - Pdraft_i)^2}$

Table 4. Results obtained via analysis of variance (ANOVA) performed on test variables affecting the draft force.**Cuadro 4.** Resultados obtenidos mediante el análisis de varianza (ANOVA), realizado sobre variables de ensayo que afectan la fuerza de tiro.

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Replicate	0.001	1	0.001	0.000	0.983
Soil moisture content (MC)	4.634	2	2.317	5.171	0.011
Plowing depth (PD)	34.474	2	17.237	38.464	0.000
Plowing speed (PS)	16.146	2	8.073	18.015	0.000
MC × PD	0.537	2	0.269	0.600	0.555
MC × PS	0.019	4	0.005	0.011	1.000
PD × PS	0.323	4	0.081	0.180	0.947
MC × PD × PS	0.571	4	0.143	0.318	0.864
Error	14.788	33	0.448		
Total	1818.800	54			
Corrected Total	72.425	53			

soil at the interface. Moreover, the draft forces on tillage implements demonstrate a significant increase with tillage speed (Naderloo *et al.*, 2009). An extant study demonstrates that the draft force increases in tillage implements with increase in tillage depth and forward speed (Wandkar *et al.*, 2013). Variation in the mean value of the draft force corresponding to changes in the plowing speed at different values of other input variables is depicted in Figure 1.

As observed, the draft force varies in the range of 4.05–8.57 kN. The highest value of draft force (8.57 kN), corresponded to a plowing speed of 4.32 km h⁻¹, 16 cm plowing depth, and soil moisture content of 9.9% db. An increase of approximately 33% in soil-moisture content from 9.9–13.2% db at a plowing depth 16 cm and plowing speed of 4.32 km h⁻¹ yielded a nearly 14.7% decrease in the draft force. Rashidi *et al.* (2013a) reported an explanation on the effect of increasing soil-moisture content on plow draft force. They reasoned that dry soil exerts a much larger draft force, and therefore, requires more power to perform the plowing operation when compared against moist soil. This is due to the lubricating effect of moisture films surrounding soil particles as well as a decrease in soil strength caused by the presence of moisture.

Draft prediction analysis

As already mentioned, the DTREG software package was used in this study for predicting the draft force acting on a moldboard plow. DTREG

en el Cuadro 3, donde O_{draft} denota la fuerza de tiro observada (kN), mientras que P_{draft} denota la fuerza de tiro prevista (kN), y n denota el número de patrones.

RESULTADOS Y DISCUSIÓN

Análisis estadístico

Los resultados obtenidos a través del ANDEVA sobre los efectos de los parámetros de entrada en la variación de los parámetros de salida se presentan en el Cuadro 4. Los resultados demuestran que la velocidad de arado, la profundidad de arado y el contenido de humedad del suelo afectan significativamente ($p \leq 0.05$) la fuerza de tiro que actúa sobre el arado de vertederas. Las mayores profundidades de arado dan como resultado la generación de una mayor fuerza de reacción ejercida por el suelo en la interfase. Además, las fuerzas de tiro en las herramientas de labranza demuestran un aumento significativo con la velocidad de labranza (Naderloo *et al.*, 2009). Un estudio previo demuestra que la fuerza de tiro aumenta en las herramientas de labranza con el aumento de la profundidad de labranza y la velocidad de avance (Wandkar *et al.*, 2013). La variación en el valor medio de la fuerza de tiro que corresponde a los cambios en la velocidad de arado en diferentes valores de otras variables de entrada se describe en la Figura 1.

Como se observa, la fuerza de tiro varía en amplitud de 4.05–8.57 kN. El valor más alto de la fuerza de tiro (8.57 kN) correspondió a una velocidad de arado de 4.32 km h⁻¹, 16 cm de profundidad de arado y un




Figure 1. Variation in measured values of draft force versus plowing speed at different values of other input variables.

Figura 1. Variación en los valores medidos de la fuerza de tiro contra la velocidad de arado con diferentes valores de otras variables de entrada.

offers a choice of different SVM models to be used in the analysis depending on the SVM type and the kernel function to be used. The two SVM models and four kernel functions investigated in this study yielded eight combinations of SVR model that can be employed, as listed in Table 5. After generating the SVM models, DTREG provides a report on

contenido de humedad del suelo de 9.9% bs. Un aumento de aproximadamente 33% en el contenido de humedad del suelo de 9.9-13.2% bs, a una profundidad de arado de 16 cm y una velocidad de arado de 4.32 km h⁻¹ produjo una disminución de casi 14.7% en la fuerza de tiro. Rashidi *et al.* (2013a) aportaron una explicación al efecto del aumento del contenido de humedad del suelo en la fuerza de tiro del arado. Ellos razonaron que el suelo seco ejerce una fuerza de tiro mucho mayor, por lo tanto, requiere más potencia para realizar la operación de arado en comparación con el suelo húmedo. Esto se debe al efecto lubricante de las películas de humedad que rodean a las partículas del suelo, así como a la disminución de la resistencia del suelo causada por la presencia de humedad.

Análisis de la predicción de fuerza de tiro

Como se mencionó anteriormente, el programa DTREG se utilizó en este estudio para predecir la fuerza de tiro que actúa sobre un arado de vertederas. DTREG ofrece una selección de diferentes modelos de SVM para usarse en el análisis dependiendo del tipo de SVM y de la función de núcleos por utilizar. Los dos modelos SVM y las cuatro funciones de núcleo investigados en este estudio produjeron ocho combinaciones de modelos SVR que pueden usarse, como se indica en el Cuadro 5. Después de generar los modelos SVM, DTREG proporciona un informe sobre la importancia relativa de las variables predictoras. El software emplea el método de validación cruzada en magnitud-V para validar los modelos SVM, y se observó que la selección de los parámetros del modelo influye en gran medida en la precisión del modelo SVM. El Cuadro 6 enumera los valores de los parámetros de núcleo obtenidos después del entrenamiento de los modelos SVM.

La fuerza de tiro se eligió como variable objetivo, mientras que el contenido de humedad del suelo, la profundidad de arado y la velocidad de arado se consideraron variables predictoras. Una vez que el modelo SVM se entrenó y estableció, pudo predecir los valores de la variable objetivo con base en los valores correspondientes de las variables predictoras. El archivo de informe de datos de validación generado por DTREG incluye todos los valores predichos de la variable objetivo. La precisión del modelo se estimó con base en las estadísticas de datos de validación.

Table 5. SVR model combinations based on SVM model and kernel type.**Cuadro 5.** Combinaciones de modelos SVR basadas en el modelo SVM y el tipo de núcleo.

SVM model	Kernel type	SVR-model	Inputs
Epsilon-SVR	Linear	M1-SVR	PD, PS and MC
Epsilon-SVR	Radial Basis Function (RBF)	M2-SVR	PD, PS and MC
Epsilon-SVR	Polynomial degree1	M3-SVR	PD, PS and MC
Epsilon-SVR	Sigmoid	M4-SVR	PD, PS and MC
Nu-SVR	Linear	M5-SVR	PD, PS and MC
Nu-SVR	Radial Basis Function (RBF)	M6-SVR	PD, PS and MC
Nu-SVR	Polynomial degree1	M7-SVR	PD, PS and MC
Nu-SVR	Sigmoid	M8-SVR	PD, PS and MC

Table 6. Kernel parameter values obtained after training SVM models.**Cuadro 6.** Valores de parámetros de núcleo obtenidos después del entrenamiento de modelos SVM.

SVM models	E	C	Γ	P	Coef0	ν
M1-SVR	0.001	850.953		0.063		
M2-SVR	0.001	1604.774	0.123	0.012		
M3-SVR	0.001	5000.042	0.037	0.000	100	
M4-SVR	0.001	482.288	0.037	0.002	0.046	
M5-SVR	0.001	4999.996				0.228
M6-SVR	0.001	1538.009	0.037			0.601
M7-SVR	0.001	166609.939	0.408		94.322	0.247
M8-SVR	0.001	1714.004	0.037			0.228

the relative significance of predictor variables. The software employs the V-fold cross validation method for validating SVM models, and selection of model parameters was observed to greatly influence the accuracy of the SVM model. Table 6 lists values of kernel parameters obtained after training SVM models.

The draft force was chosen as the target variable while soil moisture content, plowing depth, and plowing speed were considered predictor variables. Once the SVM model was trained and established, it could predict values of the target variable based on corresponding values of predictor variables. The validation data report file generated by DTREG includes all predicted values of the target variable. The model accuracy was estimated based on validation-data statistics. The correlation coefficient and MAPE were used as model estimators. The correlation coefficient is a measure of the global fit of the model, thereby indicating how well data points fit on to a line or curve. MAPE, on the other hand, is a measure of the accuracy of a prediction model expressed as a

El coeficiente de correlación y el MAPE se utilizaron como estimadores del modelo. El coeficiente de correlación es una medida del ajuste global del modelo, el cual indica qué tan bien adecuados están los puntos de datos a una línea o curva. Mientras que MAPE es una medida de la precisión, expresada como porcentaje, de un modelo de predicción. Los resultados de este análisis demuestran que el conjunto ε -SVR de núcleos en función con base radial (M2-SVR) y valores de parámetros de $C = 1604.774$, $\varepsilon = 0.001$, $\gamma = 0.123$ y $P = 0.012$ sirven como modelo óptimo para predecir la fuerza de tiro con un tiempo de ejecución de análisis de 3.93 min. También se observó que el modelo de predicción desarrollado es mejor cuando se compara con los modelos convencionales de regresión lineal múltiple y de referencia analítica (Ahmadi, 2016), y cuando se utiliza la misma base de datos.

Con base en los datos de predicción, se calculó la raíz del error cuadrático medio en 0.288 kN, y el coeficiente de correlación entre los valores reales y los previstos fue de 0.969 (Cuadro 7). Estos valores indican

percentage. Results of this analysis demonstrate that the ϵ -SVR set with radial basis function kernel (M2-SVR) and parameter values of $C = 1604.774$, $\epsilon = 0.001$, $\gamma = 0.123$ and $P = 0.012$ serve as the optimum model for predicting the draft force with an analysis run time of 3.93 min. It was also observed that the developed prediction model is better when compared against conventional multiple linear regression and analytical benchmark models (Ahmadi, 2016), when using the same database.

Based on prediction data, the root mean squared error was calculated to be 0.288 kN, and the correlation coefficient between actual and predicted values was 0.969 (Table 7). These values indicate satisfactory performance of the proposed model. Thus, support vector regression, as a farm-machinery-management tool, can be employed for accurate prediction of the draft force acting on a moldboard plow. Besides, when using the M2-SVR model, MAPE=3.094%, thereby implying that use of the proposed model results in a prediction error of 3.094%, which indicates a very high accuracy, since training data used herein were obtained from field experiments.

As it is observed from results, the M2-SVR model yields highly accurate predictions based on on-field data and is significantly more accurate when compared against the multiple linear regression model. The actual *vs.* predicted value chart is available only after building a model, wherein the target variable

un desempeño satisfactorio del modelo propuesto. De modo que, los vectores soporte para regresión, como herramientas de gestión de maquinaria agrícola, pueden usarse para la predicción precisa de la fuerza de tiro que actúa en un arado de vertederas. Además, al utilizar el modelo M2-SVR, MAPE=3.094%, lo cual implica que el uso del modelo propuesto da como resultado un error de predicción de 3.094%, lo cual indica una precisión muy alta, ya que los datos de entrenamiento utilizados aquí se obtuvieron a partir de experimentos en campo.

Como se observa en los resultados, el modelo M2-SVR produce pronósticos de precisión alta a partir de datos de campo y es significativamente más preciso cuando se compara con el modelo de regresión lineal múltiple. El gráfico de valores reales contra los valores pronosticados solo está disponible después de construir un modelo, en el cual la variable objetivo es continua, como se muestra en la Figura 2 y la Figura 3. El gráfico de valores muestra un punto por cada fila de datos. La abscisa de un punto es el valor objetivo real, mientras que la ordenada se refiere al valor objetivo predicho correspondiente. A veces, también se llama a este tipo de gráfico, gráfico de residuales. Dado un modelo perfecto, los valores pronosticados coincidirían exactamente con los valores reales, y las abscisas y las ordenadas serían idénticas para cada punto, y todos los puntos se ubicarían en la línea diagonal dada por $x - y = 0$. Cuando los valores pronosticados difieren de los valores reales, los puntos

Table 7. Correlation coefficient (R), Maximum error, Root Mean Squared Error (RMSE), Mean Squared Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE) and Analysis run time for draft-force prediction models.

Cuadro 7. Coeficiente de Correlación (R), Error Máximo, Raíz del Error Cuadrático Medio (RMSE), Error Cuadrático Medio (MSE), Error Absoluto Medio (MAE), Error Porcentual Medio Absoluto (MAPE) y tiempo de corrida de análisis para modelos de predicción de fuerza de tiro.

SVM models	(R)	Maximum error (kN)	RMSE (kN)	MSE (kN)	MAE (kN)	MAPE (%)	Analysis run time (min)
M1-SVR	0.905	1.466	0.495	0.245	0.367	6.347	7.02
M2-SVR	0.969	0.830	0.288	0.083	0.192	3.094	3.93
M3-SVR	0.898	1.536	0.511	0.261	0.374	6.536	14.25
M4-SVR	0.808	1.589	0.507	0.257	0.381	6.618	3.97
M5-SVR	0.915	1.180	0.47	0.221	0.36	6.451	14.11
M6-SVR	0.967	0.722	0.293	0.086	0.232	3.912	5.84
M7-SVR	0.910	1.390	0.487	0.237	0.378	6.532	44.03
M8-SVR	0.912	1.220	0.479	0.229	0.377	6.610	3.10
MLR	0.912	1.286	0.475	0.226	0.376	6.605	0.19
Ahmadi (2016)	0.802	2.860	1.983	3.931	1.476	26.384	---

is continuous as shown in Figure 2 and Figure 3. Value chart displays one point for each data row. The abscissa of a point is the actual target value while the ordinate refers to the corresponding predicted target value. Such chart is, sometimes, also referred to as the residual chart. Given a perfect model, predicted values would exactly match actual values, and the abscissae and ordinates would become identical for each point, and all points would be located on the diagonal line given by $x - y = 0$. When predicted values differs from actual values, the points are offset from the diagonal line, and the vertical distance from the diagonal line to the point corresponds to the error or residual denoted by red vertical lines.

The predictive MLR model for moldboard plow draft using identical data as used in this study may be expressed as follows.

$$\text{Draft} = 1.35624 - 0.211396 \times \text{MC} + 0.302821 \times \text{PD} + 0.817368 \times \text{PS} \quad (R = 0.912) \quad (7)$$

As observed in the analysis using SVR models and presented in Table 8, the effect of plowing depth on draft-force variation is more significant compared to that of operating speed and soil moisture content.




Figure 2. Actual draft force *versus* predicted draft force for MLR model.

Figura 2. Fuerza de tiro real *versus* fuerza de tiro pronosticada para modelo MLR.

se dispersan desde la línea diagonal, y la distancia vertical desde la línea diagonal al punto corresponde al error o residuo denotado por las líneas verticales rojas.

El modelo predictivo MLR para el tiro de arado de vertederas usando datos idénticos a los utilizados en este estudio puede expresarse de la siguiente manera.

$$\text{Draft} = 1.35624 - 0.211396 \times \text{MC} + 0.302821 \times \text{PD} + 0.817368 \times \text{PS} \quad (R = 0.912) \quad (7)$$

Como se observó en el análisis que usó modelos SVR y como se presenta en el Cuadro 8, el efecto de la profundidad de arado sobre la variación de la fuerza de tiro es más significativo comparado con el de la velocidad de operación y el contenido de humedad del suelo. Esto demuestra la importancia de cada variable, y dicho hallazgo es acorde con los resultados presentados por Akbarnia *et al.* (2014). Los resultados muestran que la profundidad de arado tiene un efecto del 100% sobre la fuerza de tiro, mientras que la velocidad de arado y el contenido de humedad del suelo contribuyen con un 26.028% y un 6.893%, respectivamente, al usar el modelo M2-SVR.




Figure 3. Actual draft force *versus* predicted draft force for M2-SVR model.

Figura 3. Fuerza de tiro real *versus* fuerza de tiro pronosticada para modelo M2-SVR.

This demonstrates the importance of each variable, and the said finding agrees with the results presented by Akbarnia *et al.* (2014). The results show that plowing depth has a 100% effect on the draft force, while the plowing speed and soil moisture content contribute 26.028% and 6.893%, respectively, when employing the M2-SVR model.

CONCLUSIONS

Valuable academic knowledge and field application was achieved in determining intelligent simulation for support vector regression of the draft force of a moldboard plow (mounted-type) during a tillage operation. Draft force was influenced by three operational variables (plowing speed, plowing depth and soil moisture content), but the most important effect was plowing depth.

The best simulation environment, among the eight developed support vector regression models to draft-force prediction, was ϵ -SVR using the radial basis function; it demonstrated optimum performance.

The knowledge contributed by this research will render qualitative field operations and predict draft requirements; also promoting better farm machinery management decisions.

ACKNOWLEDGMENT

Research team acknowledge respect and gratitude to the Deanship of Scientific Research, Researchers Support Services Unit, Agricultural Research Center, and College of Food and Agriculture Sciences at the King Saud University, Saudi Arabia for their technical support.

LITERATURE CITED

Abbaspour-Gilandeh, Y., and R. Sedghi. 2013. Prediction of draft force and energy requirement for subsoiling operation with a fuzzy logic approach. *J. Agric. Mach.* 3: 104-113.
 Abbaspour-Gilandeh, Y., and R. Sedghi. 2015. Predicting soil fragmentation during tillage operation using fuzzy logic approach. *J. Terramech.* 57: 61-69.
 Aboukarima, A. M. 2012. Comparison of multiple linear regression and adaptive neuro fuzzy inference system for predicting cohesion and internal friction angle of cultivated soils. *Proceeding of the 19th Conference of the Misr Society of Agriculture Engineers.* 14-15 November 2012. pp: 1-22.
 Ahmadi, I. 2016. Development and evaluation of a draft force calculator for moldboard plow using the laws of classical mechanics. *Soil Tillage Res.* 161: 129-134.

Table 8. Variable importance (%), as predicted by different SVR models.

Cuadro 8. Importancia variable (%), según lo predicho por los diferentes modelos SVR.

SVM models	Plowing depth	Plowing speed	Soil moisture content
M1-SVR	100	21.616	4.939
M2-SVR	100	26.028	6.893
M3-SVR	100	20.744	4.644
M4-SVR	100	22.482	4.735
M5-SVR	100	29.853	11.156
M6-SVR	100	25.625	7.825
M7-SVR	100	27.429	10.358
M8-SVR	100	30.594	12.212

CONCLUSIONES

Valioso conocimiento académico se obtuvo y se logró su aplicación en campo para determinar la simulación inteligente de los vectores soporte para regresión para predecir la fuerza de tiro (tracción) en un arado de vertederas (de montaje) para operaciones de labranza. La fuerza de tiro recibió el efecto de tres variables operativas (velocidad de arado, profundidad de arado y contenido de humedad del suelo), pero el efecto más importante fue la profundidad de arado.

El mejor entorno de simulación, entre los ocho modelos de vectores soporte para regresión desarrollados para predecir la fuerza de tiro, fue ϵ -SVR y la función con base radial, ya que demostraron un desempeño óptimo.

El conocimiento aportado por esta investigación permitirá realizar operaciones de campo de calidad y la predicción de los requerimientos de fuerza de tiro, además de promover mejores decisiones en el manejo de maquinaria agrícola.

—End of the English version—



Akbarnia, A., A. Mohammadi, F. Farhani, and R. Alimardani. 2014. Simulation of draft force of winged share tillage tool using artificial neural network model. *Agric. Eng. Int.: CIGR J.* 16: 57-65.
 Alimardani, R., Y. Abbaspour-Gilandeh, A. Khalilian, A. Keyhani, and S. H. Sadati. 2009. Prediction of draft force

- and energy of subsoiling operation using ANN model. *J. Food, Agric. Environ.* 7: 537-542.
- Al-Janobi, A. A., A. M. Aboukarima, and K. A. Ahmed. 2001. Prediction of specific draft of different tillage implements using neural network. *Misr J. Agric. Eng.* 18: 699-714.
- Al-Suhaibani, S. A., A. M. Aboukarima, and I. S. Tabash. 2015. Study on the effect of soil moisture content and plowing speed on draft requirements of a moldboard plow. *J. Advances Agric.* 4: 477-486.
- Arvidsson, J., and O. Hillerstrom. 2010. Specific draught, soil fragmentation and straw incorporation for different tine and share types. *Soil and Tillage Res.* 110: 154-160.
- Choi, Y. S., K. S. Lee, and W. Y. Park. 2000. Application of a neural network to dynamic draft model. *Agric. Biosystems Eng.* 1: 67-72.
- Chu, H., J. Wei, T. Li, and K. Jia. 2016. Application of support vector regression for mid- and long-term runoff forecasting in "Yellow River Headwater" Region. *Procedia Eng.* 154: 1251-1257.
- Formato, A., S. Faugno, and G. Paolillo. 2005. Numerical simulation of soil-plow moldboard interaction. *Biosystems Eng.* 92: 309-316.
- Godwin, R. J., M. J. O' Dogherty, C. Saunders, and A. T. Balafoutis. 2007. A force prediction model for moldboard plows incorporating the effects of soil characteristic properties, plow geometric factors and plowing speed. *Biosystems Eng.* 97: 117-129.
- Huang, Y., Y. Lan, S. J. Thomson, A. Fang, W. C. Hoffmann, and R. E. Lacey. 2010. Development of soft computing and applications in agricultural and biological engineering: Review. *Comp. Elect. Agric.* 71: 107-127.
- KarimiInchebron, A., S. R. M. Seyedi, and R. T. Koloor. 2012. Investigating the effect of soil moisture content and depth on the draught, specific draught and drawbar power of a light tractor. *Int. Res. J. Appl. Basic Sci.* 3: 2289-2293.
- Khan, M. S., and P. Coulibaly. 2006. Application of support vector machine in lake water level prediction. *J. Hydrol. Eng.* 11: 199-205.
- Mohammadi, A., R. Alimardani, A. Akbarnia, and A. Akram. 2012. Modeling of draft force variation in a winged share tillage tool using fuzzy table look-up scheme. *Agric. Eng. Int.: CIGR J.* 14: 262-268.
- Naderloo, L., R. Alimadani, A. Akram, P. Javadikia and H. Z. Khanghah. 2009. Tillage depth and forward speed effects on draft of three primary tillage implements in clay loam soil. *J. Food, Agric. Environ.* 7: 382-385.
- PAES. 2001. Philippine Agricultural Engineering Standard (PAES) 121: 2001 Agricultural Machinery - Disk Plow – Specifications. 9 p.
- Rahman, A., R. L. Kushawaha, S. R. Ashrafzadeh, and S. Panigrahi. 2011. Prediction of energy requirement of a tillage tool in a soil bin using artificial neural network. ASABE Paper No. 111112. American Society of Agricultural and Biological Engineers, St. Joseph, Michigan, USA. pp: 1-14.
- Ranjbar, I., M. Rashidi, I. Najjarzadeh, A. Niazkhani, and M. Niyazadeh. 2013. Modeling of moldboard plow draft force based on tillage depth and operation speed. *Middle-East J. Scientific Res.* 17: 891-897.
- Rashidi, M., I. Najjarzadeh, B. Jaberinasab, S. M. Emadi, and M. Fayyazi. 2013a. Effect of soil moisture content, tillage depth and operation speed on draft force of moldboard plow. *Middle-East J. Scientific Res.* 16: 245-249.
- Rashidi, M., I. Najjarzadeh, S. T. Namin, F. Naserzaeim, S. H. Mirzaki, and M. Salimi Beni. 2013b. Prediction of moldboard plow draft force based on soil moisture content, tillage depth and operation speed. *American-Eurasian J. Agric. Environ. Sci.* 13: 1057-1062.
- Roul, A. K., H. Raheman, M. S. Pansare, and R. Machavaram. 2009. Prediction of draft requirement of tillage implements in sandy clay loam soil using an artificial neural network. *Biosystems Eng.* 104: 476-485.
- Sahu, R. K., and H. Raheman. 2006. Draught prediction of agricultural implements using reference tillage tools in sandy clay loam soil. *Biosystems Eng.* 94: 275-284.
- Shafaei, S. M., M. Loghavi, and S. Kamgar. 2017. Appraisal of Takagi-Sugeno-Kang type of adaptive neuro-fuzzy inference system for draft force prediction of chisel plow implement. *Comp. Elect. Agric.* 142: 406-415.
- Sherrrod, P. H. 2003. DTREG. predictive modeling software. www.dtreg.com.
- Thomas, S., G. N. Pillai, and K. Pal. 2017. Prediction of peak ground acceleration using ϵ -SVR, ν -SVR and Ls-SVR algorithm. *Geomatics, Natural Hazards and Risk.* 8: 177-193.
- Wandkar, S. V., P. P. Jadhav, B. S. Gholap, V. V. Gonjari, and S. G. Pawar. 2013. Influence of forward speed and tillage depth on draft of primary tillage implements in sandy loam soil. *IAEJ.* 22: 26-30.
- Woodsend, K., and J. Gondzio. 2009. Hybrid MPI/open MP parallel linear support vector machine training. *J. Machine Learning Res.* 10: 1937-1953.

