

PARADIGMA EVOLUTIVO EN LA FORMULACIÓN DE RACIONES PARA GANADO BOVINO

EVOLUTIONARY PARADIGM IN THE FORMULATION OF RATIONS FOR BOVINE CATTLE

Blanca Cecilia López Ramírez

Tecnológico Nacional de México en Roque
bcelopez@gmail.com

Luis Ramón Sánchez Rico

Tecnológico Nacional de México en Roque
luisrs@itroque.edu.mx

Giovanni Guzmán Lugo

Centro de Investigación en Computación
giovanni.guzman@gmail.com

Mauricio Flores Hernández

Tecnológico Nacional de México en Roque
mau1361317@gmail.com

Resumen

El interés de la industria ganadera por la salud del animal ha impulsado el estudio de la preparación de raciones con los nutrientes necesarios para un mayor rendimiento en la producción de leche. El cuidado de una buena alimentación está directamente relacionado con la calidad y cantidad de leche producida por una vaca. Este trabajo propone una técnica evolutiva para la formulación de raciones con el objetivo de maximizar la producción de leche en el ganado bovino. El problema de la formulación de raciones es complejo debido a que no sólo se considera su peso, edad, especie y estado físico del animal, sino también, factores como la proteína cruda digerible, los nutrientes totales digeribles y la materia seca digerible son importantes en este proceso. En este trabajo, un Algoritmo Genético con representación binaria es propuesto para resolver el problema en la formulación de raciones. Los resultados obtenidos muestran que la aplicación del Algoritmo Genético en la preparación de raciones es una alternativa muy competitiva y

eficiente, que alcanza un mayor rendimiento que los métodos tradicionales en la producción de leche para ganado bovino.

Palabra(s) Clave: Algoritmo genético, Nutrición animal, Nutrientes, Rendimiento.

Abstract

This work proposes an evolutionary technique for the formulation of food rations with the objective to maximize milk production in cattle. The interest of the livestock industry by the animal's health has promoted the study of the preparation of rations with the necessary nutrients for increased performance in the production of milk. The care of a good power supply guarantees the quality and quantity of milk produced by a cow. The problem of ration formulation is complex due to the fact that not only is considered your weight, age and physical condition of the animal, but in addition, factors such as the digestible crude protein, total digestible nutrients and the digestible dry matter are important in this process. A Genetic Algorithm with binary representation is proposed in the formulation of rations. The results are interesting and competitive reaching greater performance in the production of milk.

Keywords: *Animal nutrition, Genetic algorithm, Nutrients, Performance.*

1. Introducción

La industria ganadera ha llegado a ser uno de los sectores productivos más importantes de la economía [Food and A. O. of the United Nations, 2006] [SAGARPA, 2018]. La técnica de alimentación para el ganado bovino consiste de factores nutricionales que impactan en el proceso de producción y reproducción de la vida animal.

Aunque el alimento es una sustancia que contiene un valor nutricional, su aprovechamiento es relativo a la ración y a la especie del animal que lo consume. El valor nutricional que contiene un alimento está compuesto por ingredientes usados en raciones.

Una ración es la cantidad necesaria de alimento ingerido por los seres vivos en un día y los ingredientes que la constituyen deben garantizar que contienen los nutrientes necesarios para mantener la buena salud del animal, a esto se le conoce

como equilibrio alimenticio. Los nutrientes son sustancias que se encuentran en los alimentos tanto de origen animal como vegetal; existiendo una gran variedad de nutrientes en una dieta diaria para el ganado bovino [Miller y Cuhna, 1979]. Los valores nutricionales son influenciados por varios factores, entre los que destacan: la edad del animal, el peso, si está en lactancia, reproducción, su nivel de producción de leche, así como el ejercicio físico que debe realizar.

La industria ganadera invierte una gran parte de sus recursos en la alimentación del ganado bovino, su productividad en carne y leche depende del estado físico del animal. Es por lo anterior que, en los últimos años, los ganaderos han invertido recursos en la formulación de raciones para el ganado bovino. La formulación de raciones consiste en la selección de ingredientes con un valor nutricional adecuado a los factores físicos y reproductivos del animal.

Un Algoritmo Genético (AG) es un paradigma estocástico de la computación evolutiva que imita el proceso evolutivo de los seres vivos [López-Ramírez y Mezura-Montes, 2007]. Ha sido empleado para solucionar problemas de optimización y durante los últimos años ha sido creciente el desarrollo de éstas heurísticas y su aplicación se ha extendido a diversas áreas. Es una técnica muy popular por su eficiencia y sencillez, no requiere de guía durante la búsqueda de soluciones. Aunque existen versiones según la representación de los datos del problema en contexto, también ha sido modificado durante el proceso evolutivo con el objetivo de mejorar la búsqueda de soluciones.

A lo largo de más de 60 años, se han empleado diversos métodos de formulación de raciones con la finalidad de optimizar costos y el rendimiento del ganado [Council, 2000]. La formulación de una dieta es un problema complejo debido a la diversidad de variables como son: los tipos de alimentos, el contenido de nutrientes en la ración, la calidad del alimento y los requerimientos propios del animal de acuerdo con la etapa de desarrollo. En la producción de leche se consideran al menos tres factores en la formulación de una ración: proteína cruda digerible, nutrientes totales digeribles y materia seca digerible. La formulación de una ración ideal es un problema de optimización que tiene como objetivo encontrar el rendimiento en la producción de leche.

En este trabajo, se propone el uso de un AG primitivo en su versión binaria sin parámetros extras, para maximizar el rendimiento de la producción de leche en ganado bovino. Los resultados presentados son competitivos con los que se obtienen al usar heurísticas encontradas en el estado del arte, demostrando su capacidad de exploración al encontrar soluciones óptimas.

Estado del arte

La disminución de costos y el aumento en la producción de leche han sido metas específicas y no necesariamente independientes de los productores ganaderos, debido a lo anterior, es de importancia el poder formular raciones adecuadas para cada propósito sin descuidar la salud del ganado [Chappell, 1974] [Afolayan y Afolayan, 2008].

La formulación de raciones de ganado es un ejercicio complejo, se consideran factores como son los requerimientos del animal y la composición de los nutrientes del alimento [Sirisatien *et al.*, 2009] [Zioganas, 1981] [Rehman y Romero, 1987] [O'Connor, 1985]. La dieta formulada tiene que ser lo suficientemente aceptable para estimular el consumo por parte de los animales, por lo tanto, es necesario conocer los requerimientos, así como los nutrientes y composición de los mismos. Los nutrientes en la alimentación deben ser digeribles para no ocasionar ninguna perturbación en el estado físico del animal [Abbass, 2001].

Existen varios métodos en la formulación de una dieta para los animales, todos ellos tienen el mismo objetivo; proporcionar los nutrientes balanceados requeridos. Entre ellos se encuentran el método cuadro de Pearson, que muestra las proporciones de dos ingredientes a ser mezclados, obteniendo los nutrientes particulares [Afolayan y Afolayan, 2008] [Hillier y Lieberman, 2008]. Sin embargo, al ser utilizada, no garantiza un equilibrio de proteínas en la alimentación. Otra técnica alternativa consiste en usar ecuaciones simultáneas algebraicas capaces de equilibrar dos nutrientes a la vez; por lo tanto, no es práctico para la solución de un problema que requiera de un número mayor de ingredientes [Engelbrecht, 2008].

El método más popular es el de ensayo y error, la formulación se realiza de manera manual o mediante el uso de hoja de cálculo. Sin embargo, para poder obtener el

resultado óptimo, este método requiere de mucho tiempo de elaboración, sobre todo cuando existen demasiados ingredientes y nutrientes [Rehman y Romero, 1987]. Waugh fue el primer investigador quien utilizó programación matemática para la formulación de raciones. Aunque Waugh no fue un nutriólogo en animales, ayudó en la solución de formulación de raciones para más de dos nutrientes [Forsyth, 1995] [Alexander y Wood, 2006] [B.M.A y Cuzon, 1980] [Candler, 1960]. A partir de su trabajo se propusieron otros trabajos basados en la programación lineal para tratar la formulación de dietas en diferentes especies de animales [O'Connor, 1985] [Sirisatien *et al.*, 2007].

Por otra parte, se conocen otros estudios donde se utilizó la técnica de la programación lineal para minimizar costos sin descuidar los valores nutritivos de los alimentos [Chappell, 1974] [Waugh, 1951]. Asimismo, la programación no lineal se ha empleado para la optimización de la dieta de pollos, logrando la variación de ingredientes para obtener el máximo peso obtenido en su crecimiento [Guevara, 2004].

Existen otras técnicas heurísticas que han sido aplicadas por los investigadores para la formulación de raciones [Abbass, 2001] [Cadenas *et al.*, 2004] [Furuya y Minami, 1997] [Karaboga, 1997]. Sin embargo, aunque existen diversos trabajos enfocados por encontrar el equilibrio nutricional y el aporte energético, se afirma que no existen antecedentes directos que resuelven la asignación de nutrientes alimenticios disponibles para el ganado lechero [Notte y Pedemonte, 2012].

Los algoritmos genéticos han tenido éxito para la solución de problemas no lineales con restricciones. Generalmente, estas técnicas son apegadas a la problemática del mundo real y las restricciones deben cumplir con una meta. Un AG es eficiente en la búsqueda de soluciones frente a problemas no lineales. Existen estudios de su aplicación en el área de nutrición animal con el objetivo de la formulación de raciones utilizando funciones de penalización y a detalle se pueden encontrar en el trabajo de Furuya *et al.* [1997] [Gupta y Kuntal, 2013], Rahman *et al.* [2015], presentaron un AG en la formulación de dietas para los camarones, el objetivo fue minimizar los costos considerando una gran variedad de ingredientes y obtuvieron resultados relevantes para el área de acuicultura.

2. Métodos

El AG cuenta con una rutina computacional capaz de resolver problemas de optimización matemática a gran escala. El éxito de los resultados depende en gran parte de las especificaciones del problema a optimizar. Formalmente, el problema de optimización se compone del espacio de búsqueda de soluciones X y la función objetivo F . Resolver un problema de optimización S , ZF resolviendo ecuación 1.

$$\text{Minimizar o Maximizar } F(X) \quad (1)$$

Sujeto a las restricciones, ecuaciones 2 y 3.

$$g_i(Xg, n) \leq 0, i = 1, \dots, q \quad (2)$$

$$h_j(Xg, n) = 0, j = q + 1, \dots, m \quad (3)$$

En donde X es el vector de soluciones compuesto por las variables de decisión o variables de diseño $X = (x_1, \dots, x_n)$ representados por una n -tupla, donde x_i ($i = 1, \dots, n$).

Generalmente, las variables de diseño son parámetros geométricos que delimitan el rango de variabilidad en el espacio de búsqueda con un valor de li como límite superior y el valor de ls el inferior, ecuación 4.

$$li \leq xi \leq ls \quad (4)$$

El espacio de búsqueda S lo conforman los ejes coordenados de un plano diseñado en n -dimensiones, en el que se representa una variable de decisión x_i donde ($i = 1, \dots, n$). Cualquier punto dentro de la zona factible ZF representa una solución al problema.

La función objetivo F existe para cualquier punto en el espacio de búsqueda, si las variables de decisión se alteran, entonces el valor de la función se modifica.

Las funciones g y h son restricciones de igualdad y desigualdad respectivamente, en ingeniería, las restricciones se clasifican en dos tipos: funcionales o suaves, que muestran el límite de desempeño o de comportamiento, y laterales o duras, las cuales representan limitaciones físicas de diseño.

Algoritmos Evolutivos (AEs)

Desde hace más de cuatro décadas han sido empleados los Aes y son conocidos como paradigmas de computación estocástica.

Su metáfora consiste en imitar la evolución natural de las especies; emplea procesos de intercambio y alteración genética para reproducir individuos y medir de manera probabilística la supervivencia del más apto. La implementación computacional de un AE se enfoca en el ambiente como el problema mismo, sus individuos representan la solución al problema y ellos son evaluados (aptos) de acuerdo a la calidad de la solución del problema.

Algoritmos Genéticos (AGs)

Los algoritmos genéticos fueron propuestos originalmente por John Holland en 1960, surgen como métodos de comportamiento adaptativo que conservan los mecanismos más importantes de los sistemas naturales motivados por el aprendizaje máquina. Su representación puede ser binaria o real. El operador principal es la cruce sexual mientras que el operador secundario es la mutación, la selección de padres para la reproducción es probabilística. El esquema de un simple AG tradicional fue presentado por Goldberg *et al.* [1989] [Eiben y Smith, 2003] y se sintetiza en la tabla 1.

Tabla 1 Esquema de un simple AG.

Operación	Opción
Representación	Cadena de Bits
Recombinación	Cruza de un punto
Mutación	Cambio de bit
Selección de padres	Aptitud proporcional
Selección de sobrevivientes	Generacional

Fuente: [Goldberg *et al.*, 1989].

Representación de un Algoritmo AG

Aunque Holland propone la representación de nuevos alfabetos, la codificación binaria es la representación tradicional y la más empleada. En computación evolutiva, esta representación se le conoce como cromosoma y codifica las soluciones de un problema. La representación con números reales es común con

otras técnicas, se ha demostrado que los alfabetos grandes tienen una gran cantidad de aplicaciones del mundo real [López y Cruz, 2014] [Cruz y Coello, 2003] [Jiménez *et al.*, 2014].

Operadores de un Algoritmo AG

La recombinación proporciona la información de nuevas soluciones proporcionadas por información de una o más soluciones de individuos padres. El operador principal es la cruce sexual, en su versión original se utiliza la cruce de un punto. El segundo operador de variación es la mutación, consiste en una perturbación al esquema de codificación basa en una probabilidad de cambio. En la tabla 2 se muestran los pasos básicos de un AG, donde X_g representa el vector de la solución. N es el número total de vectores de solución del problema. $FAE(X_{g,n})$, representa el valor de amplitud de cada vector de solución en g generación. O_g es el individuo mutuo. Para este proceso es importante puntualizar lo siguiente:

- La selección de padres del AG se realizará de forma probabilística con base en la aptitud, la selección de padres es de forma generacional.
- Para la selección de sobrevivientes de un algoritmo AG existe elitismo en un AG por naturaleza. El término elitismo se define como el hecho de pasar intacto el cromosoma a la siguiente generación, sin alteración por parte de los operadores de recombinación y mutación.

Tabla 2 Pasos básicos de un Algoritmo Genético.

1	Begin
2	$k=0$
3	Generar una población inicial X_g de N individuos $X_g = \{X_{g,n} n=1, \dots, N\}$
4	Do
5	Evaluar la aptitud de cada individuo $X_{g,n} \in X_g$
6	$g = g+1$
7	Seleccionar probabilísticamente 2 padres
8	Aplicar el operador de recombinación cruce a los 2 padres seleccionados para generar a los 2 hijos O_g
9	Aplicar el operador de mutación a los hijos O_g
10	Evaluar a los hijos mutados
11	Evaluar la actitud de cada individuo $X_{g,n} \in X_g$
12	Selección generacional. Los hijos sobreviven, los padres mueren
13	Hasta que la condición sea satisfecha
14	End

Fuente: Elaboración propia.

Este trabajo presenta un algoritmo genético binario en su versión canónica sin parámetros extras considerando el número total de nutrientes digeribles, la proteína cruda digerible y la materia seca digerible como variables para preparar la dieta del animal.

Se propone el uso de un AG versión binaria, estimar la producción de leche utilizando el modelo definido en NRC 2001 [Correa, 2001] empleado por Gupta [2013] y Saxena [2011].

Saxena estudió vacas Sahiwal lecheras en un periodo de lactancia, entre la segunda y quinta etapa, éstas fueron alimentadas con mezclas de alimentos concentrados en isonitrogenados e isocalóricos, como el cacahuate, la semilla de algodón y forraje verde, que proporciona el resto de la proteína cruda digerible, y para otorgar los requisitos de materia seca y energía. Además de lo anterior, factores como el peso, la edad y los nutrientes necesarios fueron considerados para obtener el rendimiento en la producción de leche. Por lo tanto, la eficiencia en la producción de leche considera la proteína cruda digerible, los nutrientes digeribles totales y la materia seca digerible con base en la estructura física del animal. La función objetivo a maximizar se muestra en la ecuación 5.

$$f(x) = ax_2^2 - bx_3^2 + cx_1 - dx_2 + ex_3 + f \quad (5)$$

Donde x_1 corresponde a la proteína cruda digerible, x_2 son los nutrientes digeribles totales, x_3 es la materia seca digerible. Los límites de los factores son: $608.6718 \leq x_1 \leq 782.978$, $60.641 \leq x_2 \leq 75.943$ y $366.0412 \leq x_3 \leq 508.9343$. Las constantes a, b, c, d, e, f corresponden a 4.1792442 , $-4.082239204 \times 10^{-6}$, -0.114836671 , -560.0786654 , $4.145857585 \times 10^{-3}$, 19255.68675 , respectivamente.

- **Experimento 1.** Los parámetros del AG en su versión binaria son: porcentaje de cruce 0.3, porcentaje de mutación 0.001, tamaño de población 100 y número de generaciones {100, 200, 300, 400, 500, 600, 700, 800, 900, 1000, 2000, 3000, 4000, 5000}. Las variables son las originales de la ecuación 5.
- **Experimento 2.** Los parámetros de la técnica son porcentaje de cruce 0.3, porcentaje de mutación 0.001, tamaño de población 100 y número de generaciones {100, 200, 300, 400, 500, 600, 700, 800, 900, 1000, 2000,

3000, 4000, 5000}. Radha Gupta [2018] propone un cambio en los límites de las variables de la ecuación 5 con el objetivo de mejorar los resultados en sus experimentos, quedando $630 \leq x_1 \leq 682$, $66 \leq x_2 \leq 70$, $366 \leq x_3 \leq 480$.

- **Experimento 3.** Los parámetros utilizados para realizar el experimento 3 son los siguientes: porcentaje de cruce 0.5, porcentaje de mutación 0.3, tamaño de población 400, parámetros propuestos para un AG en [Notte y Pedemonte, 2012]. Número de generaciones {100, 200, 800, 1200, 1500} y el valor de las variables son las originales de la Ecuación 5.

Los experimentos son implementados en un equipo de cómputo con las siguientes características: procesador Intel i3 64x2 de 2.0Ghz, con 4GB de memoria RAM. Sistema operativo Linux. Se realizaron 30 ejecuciones independientes para cada parámetro y por cada experimento.

3. Resultados

Para llevar a cabo el primer experimento, se tomaron en cuenta los parámetros descritos en la tabla 3.

Tabla 3 Escenario del AG propuesto en el Experimento 1.

Operación	Opción
Representación	Cadena de bits
Recombinación	0.3
Mutación	0.001
Selección de padres	100 individuos
Selección de sobrevivientes	Generacional.

Fuente: Elaboración propia.

Los resultados del experimento 1 son presentados en la tabla 4, ahí se muestran las cantidades de cada factor en gm/kg de peso y el valor de la función objetivo f^* . La primera columna presenta el número de generaciones en los que fue ejecutado el AG. La tercera columna presenta los resultados de Gupta [2018]. Los valores encontrados por nuestra propuesta están en la última columna.

Tabla 4 Comparativa de resultados del experimento 1.

Experimento 1			
Pob	Var	AgGrupta	AgPropuesto
100	x_1	749.0624	740.42981
	x_2	73.5973	75.55861
	x_3	432.3138	475.29242
	f^*	759.5984	882.73582
200	x_1	755.6987	631.45855
	x_2	72.4891	75.58851
	x_3	495.7266	477.65212
	f^*	704.4718	872.14865
300	x_1	744.6752	611.01695
	x_2	74.2517	75.85172
	x_3	491.5240	451.56297
	f^*	796.9501	889.17577
400	x_1	729.9346	671.67831
	x_2	72.8592	75.29254
	x_3	457.8180	370.80021
	f^*	719.0342	856.04674
500	x_1	750.7326	722.29776
	x_2	73.6261	75.30131
	x_3	475.2268	462.09346
	f^*	761.3943	862.53514
600	x_1	747.5276	610.09994
	x_2	71.5456	75.78220
	x_3	472.9012	401.27770
	f^*	664.0140	883.91774
700	x_1	748.0788	712.54737
	x_2	72.9356	75.69866
	x_3	463.3000	442.99368
	f^*	724.8789	889.61335
800	x_1	721.3220	644.99898
	x_2	72.9743	75.08979
	x_3	465.8431	472.73591
	f^*	723.7324	839.18516
900	x_1	759.4326	673.38079
	x_2	73.2797	75.50590
	x_3	482.3860	501.15685
	f^*	743.7354	871.28448
1000	x_1	724.1868	722.10099
	x_2	73.1996	75.47566
	x_3	484.8339	382.86159
	f^*	735.5141	874.67136
2000	x_1	722.4416	632.35320
	x_2	72.5642	74.25893
	x_3	482.3343	484.64174
	f^*	704.1149	784.48936

Fuente: Elaboración propia.

Tabla 4 Comparativa de resultados del experimento 1 (continuación).

Experimento 1			
Pob	Var	AgGrupta	AgPropuesto
3000	x_1	747.1494	679.27110
	x_2	74.6055	75.67149
	x_3	474.6072	451.54526
	f^*	819.1805	883.82553
4000	x_1	724.4928	767.68824
	x_2	74.5268	75.71188
	x_3	472.6285	476.90735
	f^*	811.6016	896.92031
5000	x_1	759.6734	647.90448
	x_2	73.2089	74.09044
	x_3	477.6959	393.75403
	f^*	740.0712	776.12989

Fuente: Elaboración propia.

Aunque el algoritmo presentado por Gupta resultó ser competitivo frente a otra heurística de programación no lineal, el AG propuesto mejora hasta en un 10%. Por otro lado, Gupta obtiene el óptimo global de su técnica en 3000 generaciones con un valor de $f^* = 819.1805$, sin embargo, con el AG propuesto, a partir de 100 generaciones mejoran el óptimo global de Gupta, siendo de $f^* = 882.73582$. El óptimo global encontrado por nuestra propuesta al término del experimento demuestra un mayor rendimiento de leche con un valor de $f^* = 896.92031$.

En ambas tablas 4 y 5, se presentan los resultados del AG propuesto y los resultados del AG de Gupta. La primera columna presenta el número de generaciones para la técnica AG, la segunda contiene las variables del problema x_1 , x_2 y x_3 así como el mejor valor de aptitud de la ecuación 5, en las 30 ejecuciones independientes de cada experimento. En relación con el experimento 2, la técnica implementada presentó una capacidad de mejorar los resultados de Gupta [2013]. Por lo que se refiere a la tabla 4 que contienen los valores del experimento de Gupta y del AG propuesto en cada elemento de la matriz, nuestra propuesta exhibe un mayor rendimiento en todos los casos propuestos. Al igual que el experimento 1, se realizaron 30 ejecuciones por cada caso de prueba presentándose el mejor resultado al término de éstas. Mientras el AG de Gupta presentó su mejor resultado con 3000 generaciones, el AG propuesto contó con la habilidad de mejorar el

resultado del AG de Gupta en tan sólo 100 generaciones, en otras palabras, con tan solo 100,000 evaluaciones.

Tabla 5 Comparativa de resultados del experimento 2.

Experimento 2			
Pob	Var	AgGrupta	AgPropuesto
100	X_1	672.1468	656.06599
	X_2	69.3301	69.91793
	X_3	463.4448	376.21028
	f^*	591.8256	602.77429
200	X_1	672.0984	679.79307
	X_2	68.8769	69.84079
	X_3	428.7671	466.91774
	f^*	583.8616	603.71095
300	X_1	664.0533	649.11366
	X_2	69.3305	69.87484
	X_3	439.3848	394.24318
	f^*	590.8939	600.95333
400	X_1	662.9170	667.62859
	X_2	68.8893	69.70812
	X_3	456.7290	460.79653
	f^*	583.0166	599.24311
500	X_1	677.1270	678.51231
	X_2	69.4029	69.99906
	X_3	445.7669	431.93884
	f^*	593.8254	607.40044
600	X_1	670.5509	665.61554
	X_2	69.4217	69.99805
	X_3	444.7669	429.90480
	f^*	493.8254	605.89312
700	X_1	662.0822	651.89065
	X_2	69.4115	69.82705
	X_3	463.4859	436.51696
	f^*	592.2789	600.16824
800	X_1	672.0792	637.61957
	X_2	69.3436	69.89026
	X_3	446.4769	471.85576
	f^*	592.0740	600.05151
900	X_1	669.2510	676.49091
	X_2	69.1619	69.92766
	X_3	460.0039	433.84992
	f^*	588.3455	605.40524

Fuente: Elaboración propia.

Tabla 4 Comparativa de resultados del experimento 2 (continuación).

Experimento 2			
Pob	Var	AgGrupta	AgPropuesto
1000	x_1	674.4207	665.65072
	x_2	69.0258	69.73941
	x_3	461.6140	384.51910
	f^*	586.5650	599.67351
2000	x_1	674.7802	664.95617
	x_2	69.3380	69.66229
	x_3	456.8179	468.56674
	f^*	592.2804	597.91306
3000	x_1	662.8439	658.24030
	x_2	69.0090	69.89032
	x_3	453.2494	459.14186
	f^*	584.9496	602.41646
4000	x_1	675.4472	673.05723
	x_2	69.3782	69.86616
	x_3	441.0744	369.19929
	f^*	593.1386	603.46939
5000	x_1	670.5081	635.15455
	x_2	69.1511	69.97303
	x_3	442.2030	443.00633
	f^*	588.2859	601.77969

Fuente: Elaboración propia.

El rendimiento mejoró en un 6% en 100,000 evaluaciones, sin embargo, considerando el caso cuando se aplican 4000 generaciones que es el mayor rendimiento encontrado en todas las pruebas se tiene una ganancia de 9.5%, siendo del AG de Gupta $f^* = 819.1805$ y $f = 896.92031$ del AG propuesto. Por otro lado, para el experimento 3 son considerados los parámetros empleados en el trabajo de Notte *et al.* [2012] para evaluar la técnica propuesta. Un número de generaciones de 100, 200, 800, 1200 y 1500 con 400 individuos, los operadores de variación de mutación y cruza fueron de 0.3 y 0.5 respectivamente. La técnica propuesta presenta mejores resultados que los encontrados por Notte *et al.* [2012]. En la tabla 5 los tiempos son presentados en este experimento debido a que Notte presenta este dato como relevante para mostrar el desempeño del paradigma. En todos los casos nuestra técnica implementada encuentra mejores resultados, sin embargo, el AG propuesto supera los tiempos de Notte cuando individuos son mayores a 200.

Tabla 5 Comparativa de resultados del experimento 3.

Experimento 3			
Pob	Var	AgGrupta	AgPropuesto
100	f^*	523	862.78714
	Tiempo	0.015	0.0388
200	f^*	534	813.41539
	Tiempo	0.046	0.0756
800	f^*	546	888.92654
	Tiempo	0.7	0.3012
1200	f^*	547	816.91765
	Tiempo	1.1	0.4810
1500	f^*	548	853.37554
	Tiempo	1.3	0.5907

En la tabla 5 se indican los resultados del AG propuesto y los resultados del AG propuesto por Notte *et al.* [2012]. La primera columna presenta el número de generaciones para la técnica AG, la segunda contiene el rendimiento alcanzado y el tiempo correspondiente por la ejecución del mejor valor encontrado.

4. Discusión

Este trabajo presentó un paradigma clásico del cómputo evolutivo que muestra su capacidad para encontrar resultados sobre un tipo de problema no lineal. El AG en su versión binaria sin parámetros extras obtuvo un mayor rendimiento que los trabajos realizados por otros investigadores. En consecuencia, se presentan las formulaciones de raciones encontradas proponen el peso de la proteína cruda, los nutrientes digeribles totales y la materia seca digerible que debe ingerir el animal.

Agradecimientos

Agradecemos aos colegas Dr. Ricardo Kenji e Marianne Louise Marinho, da Universidade Estadual de Pernambuco, campus Petrolina, e a Dra. Miriam Cleide, da Universidade Federal do Vale do São Francisco, pelos conhecimentos e competências que facilitaram a pesquisa e pelo suporte no laboratório. A Fapesb pela bolsa de estudos do primeiro autor.

5. Bibliografía y Referencias

- [1] Abbass, H. A. (2001). Marriage in honey-bee optimization (mbo): A haplometrosis polygynous swarming approach. Proc. The Congress on Evolutionary Computation (CEC2001), Seoul, Korea.
- [2] Afolayan, M. O. and Afolayan, M. (2008). Nigeria oriented poultry feed formulation software requirements. *Journal of Applied Sciences Research*. vol. 4, no. 11, pp. 1596– 1602.
- [3] Alexander, P. C. & Wood, G. R. (2006). Feeding strategies for maximizing gross margin in pig production, in *Global optimization: Scientific and Engineering Case Studies*, vol. 33, pp. 33–43.
- [4] B.M.A. & Cuzon, G. (1980). Improved nutrient specification for linear programming of penaeid rations. *Aquaculture*, vol. 19, pp. 313–323.
- [5] Chappell, A. E. (1974). Linear programming cuts costs in production of animal feeds. *Operational Research Quarterly*, vol. 25, no. 1, pp. 19–26.
- [6] Candler, W. (1960). Short-cut method for the complete solution of game theory and feed-mix problems. *Econometrica*. vol. 28, no. 3, pp. 618–634.
- [7] Cadenas, H. R. P. J. M. Pelta, D. A. and Verdegay, J. L. (2004). Application of fuzzy optimization to diet problems in argentinean farms. *European Journal of Operational Research*, vol. 158, pp. 218–228.
- [8] Council, N. R. (2000). *Nutrient Requeriments of Beef Casttle*. The National Academies Press.
- [9] Cortés, N. C. & Coello, C. A. C. (2003). Multiobjective optimization using ideas from the clonal selection principle. In *GECCO*, pp. 158–170.
- [10] Correa, H. (2001). El modelo NRC-2001. *Nutrición Animal, Facultad de Ciencias Agropecuarias*, vol. 412.
- [11] Eiben, A. E. & Smith, J. E. (2003). *Introduction to Evolutionary Computing*. SpringerVerlag.
- [12] Engelbrecht, E (2008). *Optimising animal diets at the Johannesburg zoo*. University of Pretoria: Unpublished Bachelor degree thesis.
- [13] Forsyth, D. M. (1985). IChapter 5: Computer programming of beef cattle diet. Academic Press: in *Beef cattle feeding and nutrition*. 2nd Ed.

- [14] Food and A. O. of the United Nations (2016). Fao's role in animal production. <http://www.fao.org/animal-production/en/>.
- [15] Furuya, T. S. T. & Minami, Y. (1997). Evolutionary programming for mix design. *Computers and Electronics in Agriculture*. vol. 18, pp. 129–135.
- [16] Goldberg, D. E. et al. (1989). Genetic algorithms in search optimization and machine learning. vol. 412. Addison-Wesley Reading Menlo Park.
- [17] Hillier, F. S. & Lieberman, G. J. (2008). Introduction to operations research. 8th ed. New York: Mc Graw-Hill International.
- [18] Karaboga, D. (2005). An idea based on honey bee swarm for numerical optimization. Computer Engineering Department: Technical Report-TR06. Erciyes University Engineering.
- [19] Guevara, V. R. (2004). Use the nonlinear programming to optimize performance response to energy density in broiler feed formulation. *Poultry Science*, vol. 83, pp. 147– 151.
- [20] Gupta R., M. C. & Kuntal, R. S. (2018). Heuristic approaches in solving nonlinear model of livestock ration formulation.
- [21] Jimenez, F. V. Leon-Borges, J. A. and Cruz-Cortes, N. (2014). An adaptive single-point algorithm for global numerical optimization. *Expert Syst. Appl.*, vol. 41, no. 3, pp. 877–885.
- [22] López-Ramírez, B.C. & Mezura-Montes, E. (2007). Estudio del comportamiento en línea de algoritmos bio-inspirados usando medidas de desempeño en optimización con restricciones.
- [23] López-Ramírez, B.C. & Cruz-Cortés, N. (2014). Designing minimal sorting networks using a bio-inspired technique. *Computación y Sistemas*. vol. 18, no. 4.
- [24] Miller, W. J. & Cuhna, T. J. (1979). Dairy Cattle Feeding and Nutrition. Elsevier.
- [25] Rahman, R. Ramli, Abd, R. Jamari, Z. and Ku-Mahamud, K. R. (2015). Evolutionary algorithm approach for solving animal diet formulation. In 5th International Conference on Computing and Informatics (ICOCI). pp. 274–279.

- [26] Notte, G., *et al.* (2012). Algoritmos evolutivos aplicados a sistemas pastoriles de producción de leche. *Revista Argentina de Producción Animal*, vol. 32, no. 1, pp. 21–79.
- [27] O'Connor, J. (1985). Least cost dairy cattle ration formulation model based on the degradable protein system. *Journal of Dairy Science*, vol. 72, pp. 2733–2745.
- [28] Rehman, T. & Romero, C. (1987). Goal programming with penalty functions and livestock ration formulation. *Agricultural Systems*. vol. 23, no. 2, pp. 117–132.
- [29] Saxena, P. (2011). Comparison of linear and nonlinear programming techniques for animal diet. *Applied Mathematics*. vol. 1, no. 2, pp. 106–108.
- [30] Saxena, P. (2015). Animal diet formulation: optimization and simulation techniques. *Journal of Veterinary Science & Technology*. Gautam Buddha University, India.
- [31] SAGARPA, (20-11-2018). Programa de fomento ganadero: <https://www.sagarpa.gob.mx/padron-de-beneficiarios/programa-de-fomento-ganadero-2>.
- [32] Sirisatien, M. D. D. Wood, G. R. and Morel, P. C. H. (2009). Two aspects of optimal diet determination for pig production: efficiency of solution. *Journal of Global Optimum*, vol. 43, pp. 249–261.
- [33] Sirisatien, D. Wood, G. R. Dong, M. & Morel, P. C. H. (2007). Two aspects of optimal diet determination for pig production: efficiency of solution and incorporation of cost variation. *Journal of global optimization*. vol. 43, no. 2, pp. 249– 261.
- [34] Waugh, F. V. (1951). The minimum-cost dairy feed. *Journal of Farm Economics*, vol. 33, pp. 299–310.
- [35] Zioganas, C. (1981). The determination of viable, parity and optimum sizes of family-type sheep farms in the Epirus Region of Greece (PhD thesis), Wye College-University of London.