

Análisis de la producción lechera en granjas españolas

Analizando los factores clave que determinan su rendimiento.

Por: Miguel Diaz Perez de Juan y Dante Mathieu Schrantz Castro

[Acceso GitHub](#)

En un sector tan competitivo como la producción de leche, ¿qué hace que algunas granjas sean más rentables que otras? ¿Es el número de vacas, la cantidad de tierra, la mano de obra, o la alimentación lo que marca la diferencia? En este análisis, intentaremos descifrar cómo estos factores afectan la producción de leche y cuál es la influencia real de cada uno en el rendimiento de las granjas. Usaremos datos reales de unas 250 granjas del norte de España, con registros de varios años, para entender mejor el comportamiento de las variables que afectan a esta industria.

1 Objetivo

Nuestro objetivo es explorar la relación entre las variables explicativas (como vacas, tierra, mano de obra y alimentación) y la producción de leche. Usaremos nuestro conjunto de datos de producción lechera para obtener un modelo econométrico que nos permita entender cómo estos factores afectan el rendimiento de las granjas, y qué variables tienen mayor influencia.

2 ¿Por qué?

La idea de este trabajo surgió una tarde entre Dante y yo, tomando un Colacao en medio de una conversación sobre la realidad de las granjas lecheras en el norte de España, especialmente en Galicia, de donde soy. Mientras charlábamos sobre cómo muchas de estas granjas luchan por mantenerse a flote, nos dimos cuenta de que era un tema que merecía ser estudiado. ¿Por qué no explorar cómo las variables económicas y operacionales de estas granjas afectan la producción de leche? Así nació nuestra motivación para analizar estos datos, con la intención de aportar alguna luz sobre cómo mejorar la eficiencia de las granjas lecheras y, de paso, comprender mejor la rentabilidad y la sostenibilidad del sector.

3 Variables a considerar

Las variables presentes en el conjunto de datos son las siguientes:

Entradas:

- **COWS:** Número de vacas en la granja.
- **LAND:** Medida de la cantidad de terreno disponible.
- **LABOR:** Número de trabajadores en la granja.
- **FEED:** Cantidad de alimentación proporcionada.

Variables transformadas (logaritmos):

- **X1 (log de COWS):** Logaritmo del número de vacas en la granja.
- **X2 (log de LAND):** Logaritmo de la cantidad de terreno disponible.
- **X3 (log de LABOR):** Logaritmo del número de trabajadores.
- **X4 (log de FEED):** Logaritmo de la cantidad de alimentación proporcionada.

Términos Translog (variables cuadráticas y de productos cruzados):

- **X11, X22, X33, X44:** Cuadráticos de las variables logarítmicas X1, X2, X3 y X4, respectivamente.
- **X12, X13, X14, X23, X24, X34:** Productos cruzados de las variables logarítmicas, que capturan las interacciones no lineales entre ellas.

Variables dummy de año:

- **YEAR93, YEAR94, ..., YEAR98:** Variables que indican el año de observación.

Salida:

- **MILK:** La producción total de leche de cada granja.
- **YIT (log de la producción de leche):** En nuestro caso no la usaremos, usaremos directamente el output de leche -> MILK para nuestros modelos y para el Time Series.

4 Metodología - Datos de Panel

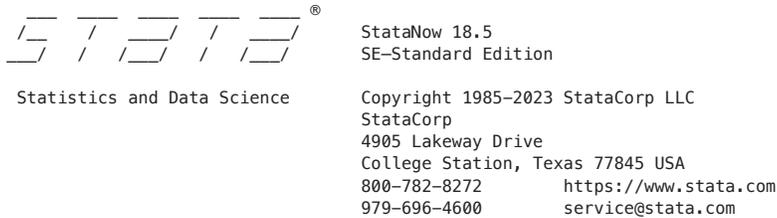
1. **Datos de Panel:** Dado que tenemos datos de varias granjas a lo largo de varios años ($N = 247$, $T = 6$), el modelo adecuado para este análisis es un modelo de **panel**. Esto nos permitirá capturar tanto las variaciones a nivel de granja como las variaciones temporales.
2. **Regresión de Panel:** Usaremos una regresión de panel para analizar cómo las variables de entrada y los efectos del año influyen en la producción de leche. Además, probaremos con efectos fijos y aleatorios para ver qué tipo de especificación se ajusta mejor a los datos.
3. **Multicolinealidad:** Antes de realizar la regresión, verificaremos si existe multicolinealidad entre las variables de entrada, usando el índice de **VIF** (Factor de Inflación de la Varianza).

5 Metodología - Time Series

- Series Temporales:** Dado que nuestro objetivo es predecir la producción de leche (**MILK**) a partir de sus valores pasados y de los lags de la variable **COWS**, aplicamos un análisis de **series temporales**. En este análisis, consideramos que la producción de leche depende de los valores previos de la variable de vacas.
- Autocorrelación y Lags:** Después de obtener la serie temporal, hemos realizado un análisis de **autocorrelación** para identificar si los **lags de la variable COWS** son significativos para predecir el valor futuro de la producción de leche. Esto nos ayudó a seleccionar los lags adecuados para el modelo.
- Modelos AR (Autoregresivos):** Para predecir la producción futura de leche, aplicamos un **modelo AR** usando los **lags de COWS** seleccionados. Esto nos permitió capturar la relación entre la producción de leche y los valores pasados de las vacas.
- Evaluación de Resultados:** Finalmente, analizamos los resultados del modelo AR, evaluando la significancia de los coeficientes.

```
In [ ]: import pandas as pd
import numpy as np
import os
os.chdir('/Applications/Stata/utilities')
from pystata import config
config.init('se')

%stata import delimited "/Users/danteschranz/Desktop/UNAV/2024-2025/Modeling Trabajo Final/CSV/dairy.csv"
```



Stata license: Single-user , expiring 25 Nov 2024
 Serial number: 401809408832
 Licensed to: Dante Schranz
 Universidad de Navarra

Notes:
 1. Unicode is supported; see help unicode_advice.
 2. Maximum number of variables is set to 5,000 but can be increased; see help set_maxvar.
 (encoding automatically selected: ISO-8859-1)
 (28 vars, 1,482 obs)

Fuentes de Datos

Los datos utilizados provienen de un conjunto de datos sobre la producción lechera en granjas españolas, disponible en la web de NYU Stern, que proporciona acceso a diversos conjuntos de datos de panel utilizados en econometría. Esta fuente es una recopilación de datasets que pueden ser utilizados para análisis económicos y agrícolas.

Se puede encontrar más información y acceder al conjunto de datos en el siguiente enlace: [NYU Stern Panel Data Sets](#).

```
In [ ]: %stata summarize
```

Variable	Obs	Mean	Std. dev.	Min	Max
farm	1,482	124	71.32624	1	247
year	1,482	95.5	1.708402	93	98
cows	1,482	22.11619	11.27415	4.5	82.3
land	1,482	12.9857	6.172051	2	45.1
milk	1,482	131106.6	92583.98	14410	727281
labor	1,482	1.671997	.5527831	1	4
feed	1,482	57941.35	47981.24	3924.141	376731.6
yit	1,482	11.57749	.6434377	9.575678	13.49707
x1	1,482	-1.40e-09	.4885577	-1.474623	1.431671
x2	1,482	5.16e-09	.4559323	-1.767564	1.348171
x3	1,482	5.43e-09	.3428585	-.4570751	.9292222
x4	1,482	-1.22e-09	.7599885	-2.410496	2.153889
x11	1,482	.1192638	.1723436	1.80e-06	1.087256
x22	1,482	.103867	.1539671	.0000273	1.562141
x33	1,482	.0587363	.0534247	.0013315	.4317269
x44	1,482	.2885964	.3847499	0	2.905246
x12	1,482	.1531676	.2855238	-.3743768	2.054143
x13	1,482	.0949598	.1775786	-.4079377	1.025777
x14	1,482	.3305641	.4785109	-.1321613	3.20606
x23	1,482	.052876	.1626291	-.4664559	1.252751
x24	1,482	.1923081	.4297219	-.9513205	3.722819
x34	1,482	.1426242	.2619795	-.5546867	1.495623
year93	1,482	.1666667	.3728038	0	1
year94	1,482	.1666667	.3728038	0	1
year95	1,482	.1666667	.3728038	0	1
year96	1,482	.1666667	.3728038	0	1
year97	1,482	.1666667	.3728038	0	1
year98	1,482	.1666667	.3728038	0	1

```
In [ ]: %stata label variable farm "Identificador único de la granja"
%stata label variable year "Año de la observación (93-98)"
%stata label variable cows "Número de vacas en la granja"
%stata label variable land "Superficie de tierra utilizada en hectáreas"
%stata label variable labor "Horas de trabajo de los empleados"
%stata label variable feed "Cantidad de alimentación proporcionada a las vacas"
%stata label variable yit "Logaritmo de la producción de leche"
%stata label variable x1 "Deviation from the mean (log)"
%stata label variable x2 "Deviation from the mean (log)"
%stata label variable x3 "Deviation from the mean (log)"
%stata label variable x4 "Deviation from the mean (log)"
%stata label variable x11 "Square of X1"
%stata label variable x22 "Square of X2"
%stata label variable x33 "Square of X3"
%stata label variable x44 "Square of X4"
%stata label variable x12 "Cross-product of X1 and X2"
%stata label variable x13 "Cross-product of X1 and X3"
%stata label variable x14 "Cross-product of X1 and X4"
%stata label variable x23 "Cross-product of X2 and X3"
%stata label variable x24 "Cross-product of X2 and X4"
%stata label variable x34 "Cross-product of X3 and X4"
%stata label variable year93 "Dummy variable for year 1993"
%stata label variable year94 "Dummy variable for year 1994"
%stata label variable year95 "Dummy variable for year 1995"
%stata label variable year96 "Dummy variable for year 1996"
%stata label variable year97 "Dummy variable for year 1997"
%stata label variable year98 "Dummy variable for year 1998"
```

```
In [ ]: %stata describe
```

```
Contains data
Observations:    1,482
Variables:       28
```

Variable name	Storage type	Display format	Value label	Variable label
farm	int	%8.0g		Identificador único de la granja
year	byte	%8.0g		Año de la observación (93-98)
cows	float	%9.0g		Número de vacas en la granja
land	float	%9.0g		Superficie de tierra utilizada en hectáreas
milk	long	%12.0g		MILK
labor	float	%9.0g		Horas de trabajo de los empleados
feed	float	%9.0g		Cantidad de alimentación proporcionada a las vacas
yit	float	%9.0g		Logaritmo de la producción de leche
x1	float	%9.0g		Deviation from the mean (log)
x2	float	%9.0g		Deviation from the mean (log)
x3	float	%9.0g		Deviation from the mean (log)
x4	float	%9.0g		Deviation from the mean (log)
x11	float	%9.0g		Square of X1
x22	float	%9.0g		Square of X2
x33	float	%9.0g		Square of X3
x44	float	%9.0g		Square of X4
x12	float	%9.0g		Cross-product of X1 and X2
x13	float	%9.0g		Cross-product of X1 and X3
x14	float	%9.0g		Cross-product of X1 and X4
x23	float	%9.0g		Cross-product of X2 and X3
x24	float	%9.0g		Cross-product of X2 and X4
x34	float	%9.0g		Cross-product of X3 and X4
year93	byte	%8.0g		Dummy variable for year 1993
year94	byte	%8.0g		Dummy variable for year 1994
year95	byte	%8.0g		Dummy variable for year 1995
year96	byte	%8.0g		Dummy variable for year 1996
year97	byte	%8.0g		Dummy variable for year 1997
year98	byte	%8.0g		Dummy variable for year 1998

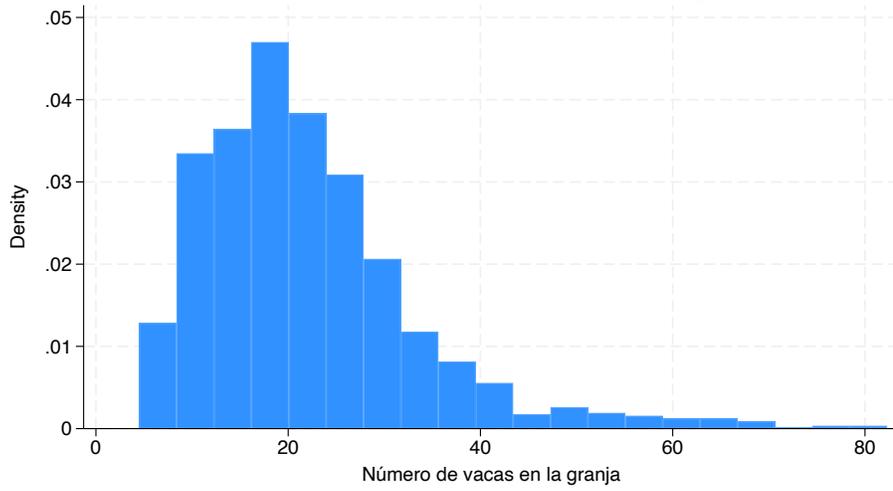
```
Sorted by:
```

```
Note: Dataset has changed since last saved.
```

```
In [ ]: %stata histogram cows, bin(20) title("Distribución del número de vacas en las granjas") xlabel(, grid) ylabel(, grid)
%stata histogram land, bin(20) title("Distribución del área de tierra utilizada en las granjas") xlabel(, grid) ylabel(, grid)
%stata histogram labor, bin(20) title("Distribución del trabajo (horas) en las granjas") xlabel(, grid) ylabel(, grid)
%stata histogram feed, bin(20) title("Distribución de la cantidad de alimento en las granjas") xlabel(, grid) ylabel(, grid)
```

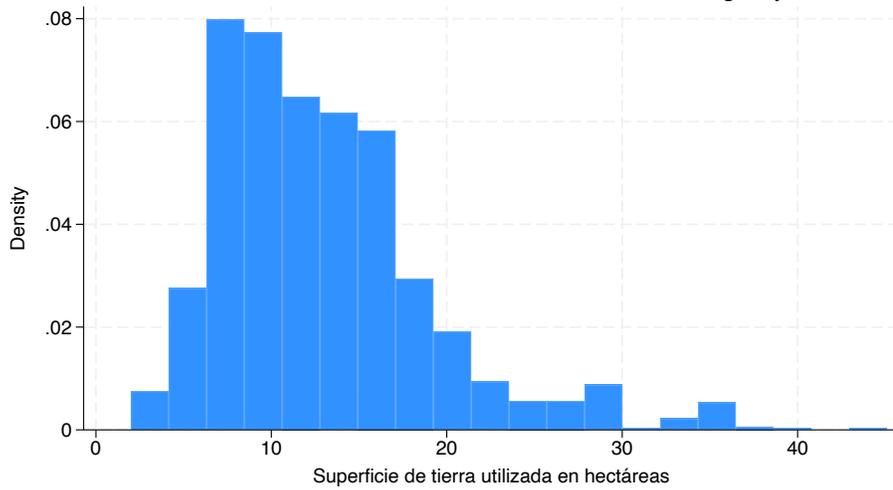
```
(bin=20, start=4.5, width=3.8900002)
```

Distribución del número de vacas en las granjas



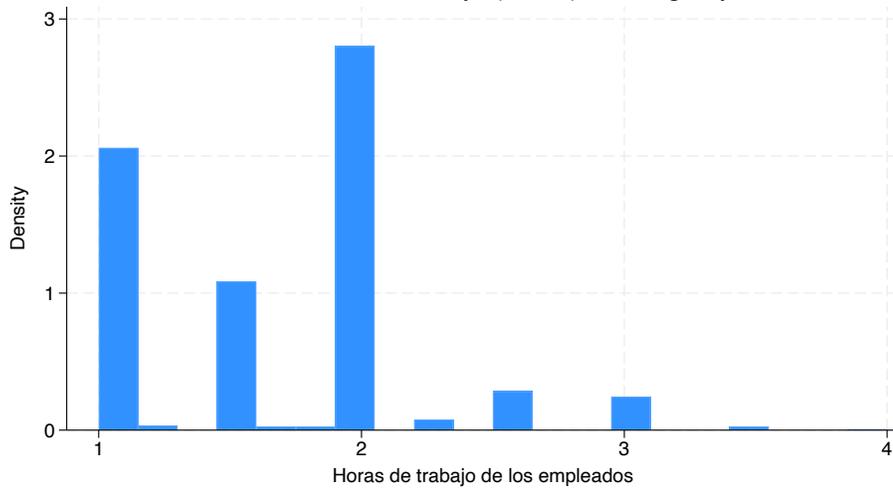
(bin=20, start=2, width=2.1549999)

Distribución del área de tierra utilizada en las granjas



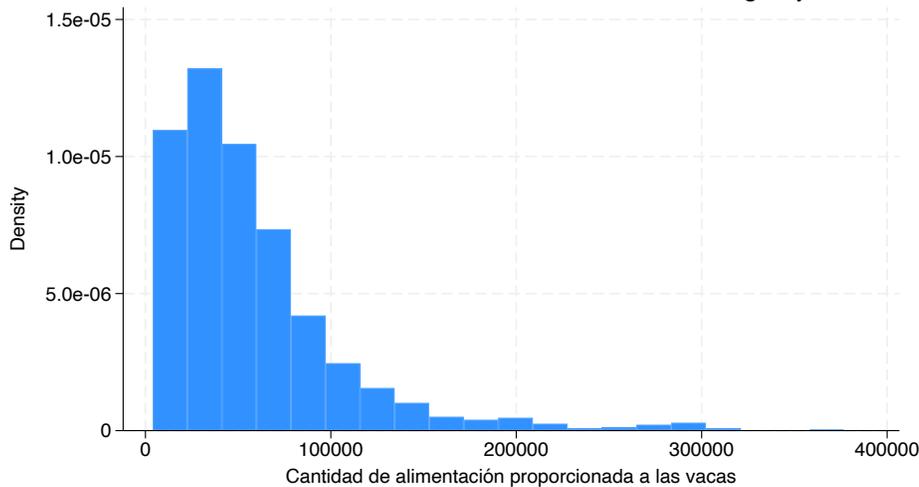
(bin=20, start=1, width=.15)

Distribución del trabajo (horas) en las granjas



(bin=20, start=3924.1411, width=18640.371)

Distribución de la cantidad de alimento en las granjas



1. Distribución del Número de Vacas en las Granjas 🐄

- **Forma de la Distribución:** La distribución es asimétrica positiva (con sesgo a la derecha), lo cual significa que la mayoría de las granjas tienen un número relativamente bajo de vacas, mientras que pocas granjas tienen un número más alto de vacas.
- **Moda:** El máximo de la distribución se encuentra entre 15 y 25 vacas, lo que sugiere que la mayoría de las granjas tienen un número de vacas en este rango.
- **Cola Derecha:** La cola derecha es larga, indicando que hay algunas granjas con un número significativamente mayor de vacas, aunque son pocas en comparación con la mayoría.

2. Distribución del Área de Tierra Utilizada en las Granjas 🌱

- **Forma de la Distribución:** La distribución del área de tierra también muestra un sesgo a la derecha, similar a la distribución del número de vacas. Esto indica que la mayoría de las granjas tienen una superficie relativamente pequeña, mientras que hay pocas con grandes extensiones de tierra.
- **Moda:** La moda se encuentra entre 8 y 12 hectáreas, lo cual sugiere que la mayoría de las granjas utilizan una superficie en este rango.
- **Cola Derecha:** La cola es más larga, lo que implica que hay algunas granjas que usan una gran cantidad de tierra, aunque son pocas.

3. Distribución del Trabajo en las Granjas 🧑‍🌾

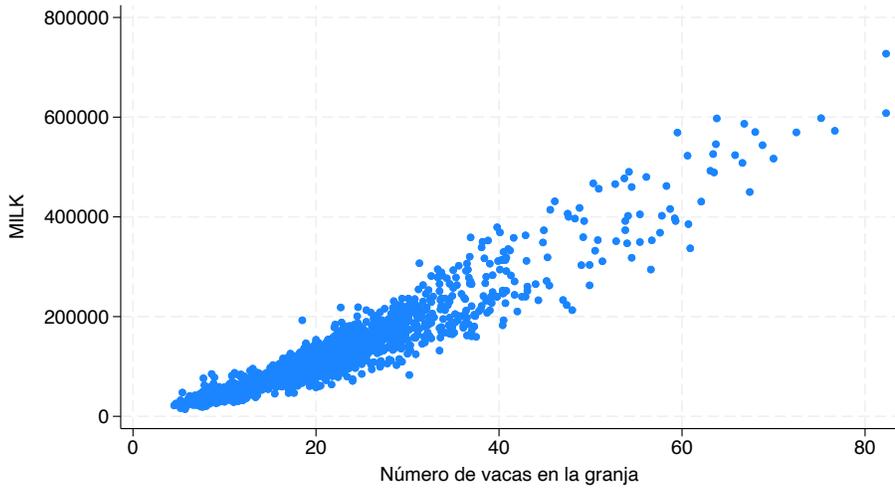
- **Forma de la Distribución:** La distribución es claramente asimétrica y discontinua, mostrando varios picos. Hay dos valores de densidad altos, correspondientes a las horas de trabajo en la granja, posiblemente indicando categorías comunes.
- **Picos:**
 - El primer pico, correspondiente a un valor de alrededor de 1, podría indicar granjas con trabajo muy reducido o granjas pequeñas con pocos empleados.
 - El segundo pico, más alto, se encuentra alrededor de 2. Esto sugiere que muchas granjas tienen una asignación más regular de trabajo, que puede corresponder a la mayoría de las actividades requeridas.
- **Anomalías:** La presencia de otros picos pequeños sugiere variabilidad en la cantidad de trabajo entre granjas. Esto podría deberse a diferencias en el tamaño de las granjas o a la estacionalidad del trabajo.

4. Distribución de la Cantidad de Alimento Proporcionada a las Vacas 🥩

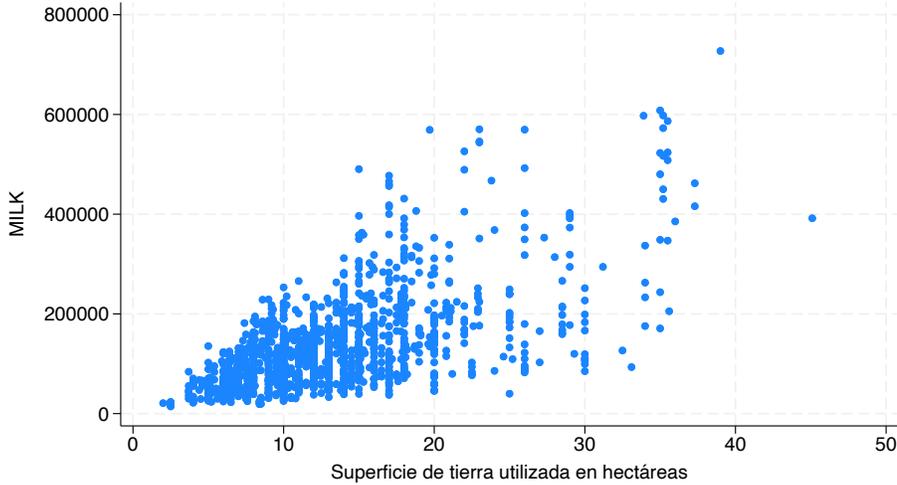
- **Forma de la Distribución:** Esta distribución tiene un sesgo positivo muy marcado, lo que indica que la mayoría de las granjas proporcionan cantidades relativamente bajas de alimento, mientras que algunas pocas granjas proporcionan una cantidad considerablemente mayor.
- **Moda:** La mayor densidad de alimentación se encuentra en el rango más bajo, probablemente por debajo de 50,000 unidades. Esto sugiere que la mayoría de las granjas tienen una política de alimentación moderada.
- **Cola Derecha Larga:** La cola derecha larga muestra que hay algunas granjas que utilizan mucha más alimentación. Esto podría deberse a que estas granjas tienen más vacas, son más intensivas, o manejan ganado con dietas más especializadas.

```
In [ ]: %stata scatter milk cows, title("Relación entre la producción de leche y el número de vacas")
%stata scatter milk land, title("Relación entre la producción de leche y el área de tierra")
%stata scatter milk feed, title("Relación entre la producción de leche y la cantidad de alimento")
```

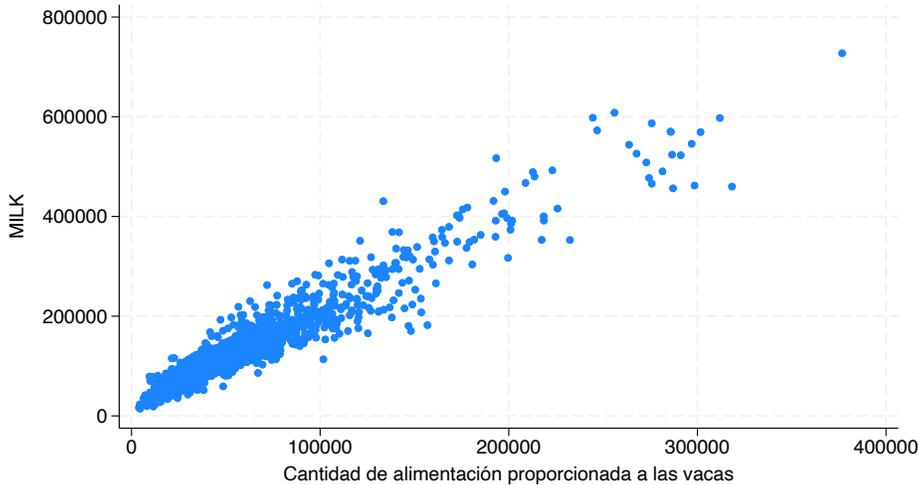
Relación entre la producción de leche y el número de vacas



Relación entre la producción de leche y el área de tierra



Relación entre la producción de leche y la cantidad de alimento



1. Relación entre Producción de Leche y Número de Vacas 🥛🐄

- **Correlación Positiva Fuerte:** El gráfico muestra una clara relación positiva entre el número de vacas y la producción de leche. A medida que aumenta el número de vacas, también lo hace la producción de leche. Esta correlación tiene una tendencia lineal, lo que indica que el número de vacas es un factor determinante y directo en la producción de leche.
- **Dispersión:** Aunque la mayoría de los puntos siguen una tendencia bastante clara, hay cierta variabilidad en la producción de leche entre granjas con un número similar de vacas, lo cual podría deberse a factores adicionales, como la eficiencia de manejo, la calidad del alimento, o la salud del ganado.

2. Relación entre Producción de Leche y Área de Tierra Utilizada 🥛🌱

- **Relación Positiva con Variabilidad:** También se observa una tendencia positiva en la relación entre la superficie de tierra utilizada y la producción de leche, aunque la correlación parece ser más dispersa comparada con el número de vacas. Esto sugiere que, aunque más tierra puede estar asociada con una mayor producción de leche, no necesariamente es el único factor, y hay más variabilidad en la producción con respecto a la cantidad de tierra.
- **Tendencia No Lineal:** La producción de leche tiende a aumentar con más área de tierra, pero no de manera tan predecible como con el número de vacas. Podría ser que el tamaño de la tierra también dependa de cómo está siendo utilizada: por ejemplo, para pastos, almacenamiento, o incluso áreas que no contribuyen directamente a la producción.

3. Relación entre Producción de Leche y Cantidad de Alimento Proporcionado 🥛🌿

- **Correlación Positiva Fuerte:** Este gráfico muestra una relación positiva muy fuerte entre la cantidad de alimento proporcionado y la producción de leche. A medida que aumenta la cantidad de alimento, también lo hace la producción de leche de manera casi proporcional. Esto sugiere que el alimento es uno de los principales factores que impulsa la producción de leche.
- **Menos Variabilidad:** La dispersión de los puntos alrededor de la línea de tendencia es menor que en los otros gráficos, lo cual indica que la alimentación tiene un impacto muy predecible y consistente sobre la producción de leche. Esto hace que sea un factor clave para incrementar la producción de manera más controlada.

```
In [ ]: %stata cor milk cows land labor feed
%stata sum milk cows land labor feed
```

(obs=1,482)

	milk	cows	land	labor	feed
milk	1.0000				
cows	0.9466	1.0000			
land	0.6228	0.7022	1.0000		
labor	0.5403	0.5618	0.3561	1.0000	
feed	0.9575	0.9003	0.5609	0.5059	1.0000

Variable	Obs	Mean	Std. dev.	Min	Max
milk	1,482	131106.6	92583.98	14410	727281
cows	1,482	22.11619	11.27415	4.5	82.3
land	1,482	12.9857	6.172051	2	45.1
labor	1,482	1.671997	.5527831	1	4
feed	1,482	57941.35	47981.24	3924.141	376731.6

Análisis de Correlación y Estadísticas Descriptivas

La producción de leche se correlaciona fuertemente con el alimento (0.9575) y el número de vacas (0.9466). Tierra (0.6228) y trabajo (0.5403) tienen una correlación más baja con la producción. La cantidad de alimento y el número de vacas son los principales factores para aumentar la producción.

```
In [ ]: %stata regress milk cows land labor feed
```

Source	SS	df	MS	Number of obs	=	1,482
Model	1.2120e+13	4	3.0299e+12	F(4, 1477)	=	7779.62
Residual	5.7524e+11	1,477	389465851	Prob > F	=	0.0000
Total	1.2695e+13	1,481	8.5718e+09	R-squared	=	0.9547
				Adj R-squared	=	0.9546
				Root MSE	=	19735

milk	Coefficient	Std. err.	t	P> t	[95% conf. interval]
cows	3644.012	129.804	28.07	0.000	3389.392 3898.632
land	-58.63673	120.1844	-0.49	0.626	-294.387 177.1136
labor	2031.415	1123.863	1.81	0.071	-173.1226 4235.952
feed	1.069114	.0252323	42.37	0.000	1.019619 1.118609
_cons	-14066.09	1828.365	-7.69	0.000	-17652.56 -10479.63

```
In [ ]: %stata vif
```

Variable	VIF	1/VIF
cows	8.14	0.122792
feed	5.57	0.179415
land	2.09	0.477924
labor	1.47	0.681362
Mean VIF	4.32	

Medimos la colinealidad entre las variables por el VIF. Un VIF que supera los 10 nos señala colinealidad, sin embargo, en esta situación, todos los VIFs se encuentran por debajo de 10, lo que indica que no existe una multicolinealidad relevante entre nuestras variables.

Las vacas y el alimento son factores esenciales para comprender la producción de leche. La región no ejerce un efecto relevante en este modelo, mientras que la variable labor ejerce un efecto residual. El modelo presenta un adecuado ajuste (R-cuadrado = 0.9547), lo que indica que la regresión recoge la mayor parte de la variabilidad en la producción láctea, aunque existen posibles mejoras.

Datos de Panel

```
In [ ]: %stata xtset farm year
```

Panel variable: farm (strongly balanced)
Time variable: year, 93 to 98
Delta: 1 unit

```
In [ ]: import pandas as pd
from linearmodels.panel import PanelOLS, RandomEffects
import numpy as np
from scipy.stats import chi2

df = pd.read_csv('/Users/danteschranzt/Desktop/UNAV/2024-2025/Modeling Trabajo Final/dairy.csv')

df = df.set_index(['FARM', 'YEAR'])
df['MILK'] = pd.to_numeric(df['MILK'], errors='coerce')
df['COWS'] = pd.to_numeric(df['COWS'], errors='coerce')
df['LAND'] = pd.to_numeric(df['LAND'], errors='coerce')
df['LABOR'] = pd.to_numeric(df['LABOR'], errors='coerce')
df['FEED'] = pd.to_numeric(df['FEED'], errors='coerce')
df['YEAR'] = df.index.get_level_values('YEAR').astype(str)

# Modelo de Efectos Fijos (FE) con efectos de tiempo (i.year en Stata)
model_fe = PanelOLS.from_formula('MILK ~ 1 + COWS + LAND + LABOR + FEED + C(YEAR) + EntityEffects', df)
results_fe = model_fe.fit()

# Modelo de Efectos Aleatorios (RE) con efectos de tiempo
model_re = RandomEffects.from_formula('MILK ~ 1 + COWS + LAND + LABOR + FEED + C(YEAR)', df)
results_re = model_re.fit()

# Obtener coeficientes y matrices de covarianza
coef_fe = results_fe.params
coef_re = results_re.params

# Asegurarse de que los índices sean los mismos
common_index = coef_fe.index.intersection(coef_re.index)
coef_fe = coef_fe.loc[common_index]
coef_re = coef_re.loc[common_index]

# Calcular la diferencia en los coeficientes y las matrices de covarianza
diff = coef_fe - coef_re
cov_fe = results_fe.cov.loc[common_index, common_index]
cov_re = results_re.cov.loc[common_index, common_index]
cov_diff = cov_fe - cov_re

# Estadística de Hausman
hausman_stat = diff.T @ np.linalg.inv(cov_diff.values) @ diff
df_hausman = len(diff)
p_value = 1 - chi2.cdf(hausman_stat, df_hausman)

# Imprimir resultados
print(f"Estadística de Hausman: {hausman_stat}")
print(f"Grados de libertad: {df_hausman}")
print(f"Valor p: {p_value}")

if p_value < 0.05:
    print("Rechazamos la hipótesis nula: El modelo de efectos fijos es más apropiado.")
else:
    print("No podemos rechazar la hipótesis nula: El modelo de efectos aleatorios es más apropiado.")

print("\nModelo de Efectos Fijos (FE):")
print(results_fe.summary)

print("\nModelo de Efectos Aleatorios (RE):")
print(results_re.summary)
```

Estadística de Hausman: 14.230518550780022

Grados de libertad: 10

Valor p: 0.16273423118973196

No podemos rechazar la hipótesis nula: El modelo de efectos aleatorios es más apropiado.

Modelo de Efectos Fijos (FE):

PanelOLS Estimation Summary

```

=====
Dep. Variable:      MILK      R-squared:           0.8805
Estimator:         PanelOLS  R-squared (Between): 0.9630
No. Observations:  1482     R-squared (Within):  0.8805
Date:              Wed, Nov 27 2024 R-squared (Overall): 0.9532
Time:              23:19:53   Log-likelihood       -1.59e+04
Cov. Estimator:    Unadjusted

Entities:          247       F-statistic:         1003.6
Avg Obs:           6.0000   P-value              0.0000
Min Obs:           6.0000   Distribution:         F(9,1226)
Max Obs:           6.0000   F-statistic (robust): 1003.6
Time periods:     6         P-value              0.0000
Avg Obs:          247.00    Distribution:         F(9,1226)
Min Obs:          247.00
Max Obs:          247.00

```

Parameter Estimates

	Parameter	Std. Err.	T-stat	P-value	Lower CI	Upper CI
Intercept	-2.04e+04	4567.2	-4.4658	0.0000	-2.936e+04	-1.144e+04
COWS	3914.7	175.58	22.296	0.0000	3570.2	4259.1
LAND	206.72	165.17	1.2516	0.2110	-117.32	530.76
LABOR	2904.8	2190.0	1.3264	0.1849	-1391.7	7201.4
FEED	0.9104	0.0273	33.296	0.0000	0.8568	0.9641
C(YEAR) [T.94]	2672.1	1100.8	2.4275	0.0153	512.56	4831.7
C(YEAR) [T.95]	4982.5	1124.8	4.4298	0.0000	2775.8	7189.2
C(YEAR) [T.96]	6398.1	1169.9	5.4692	0.0000	4103.0	8693.3
C(YEAR) [T.97]	5855.9	1215.2	4.8190	0.0000	3471.9	8239.9
C(YEAR) [T.98]	7882.4	1278.0	6.1676	0.0000	5375.0	1.039e+04

F-test for Poolability: 10.786

P-value: 0.0000

Distribution: F(246,1226)

Included effects: Entity

Modelo de Efectos Aleatorios (RE):

RandomEffects Estimation Summary

```

=====
Dep. Variable:      MILK      R-squared:           0.9140
Estimator:         RandomEffects R-squared (Between): 0.9641
No. Observations:  1482     R-squared (Within):  0.8802
Date:              Wed, Nov 27 2024 R-squared (Overall): 0.9541
Time:              23:19:53   Log-likelihood       -1.604e+04
Cov. Estimator:    Unadjusted

Entities:          247       F-statistic:         1738.1
Avg Obs:           6.0000   P-value              0.0000
Min Obs:           6.0000   Distribution:         F(9,1472)
Max Obs:           6.0000   F-statistic (robust): 1738.1
Time periods:     6         P-value              0.0000
Avg Obs:          247.00    Distribution:         F(9,1472)
Min Obs:          247.00
Max Obs:          247.00

```

Parameter Estimates

	Parameter	Std. Err.	T-stat	P-value	Lower CI	Upper CI
Intercept	-2.139e+04	3028.4	-7.0632	0.0000	-2.733e+04	-1.545e+04
COWS	3932.0	139.62	28.161	0.0000	3658.1	4205.9
LAND	102.43	139.50	0.7343	0.4629	-171.21	376.06
LABOR	3259.0	1581.4	2.0609	0.0395	157.01	6361.0
FEED	0.9432	0.0250	37.674	0.0000	0.8941	0.9924
C(YEAR) [T.94]	2479.3	1099.6	2.2548	0.0243	322.38	4636.2
C(YEAR) [T.95]	4550.2	1117.3	4.0723	0.0000	2358.4	6741.9
C(YEAR) [T.96]	5713.1	1143.2	4.9974	0.0000	3470.6	7955.6
C(YEAR) [T.97]	5022.4	1169.5	4.2945	0.0000	2728.3	7316.4
C(YEAR) [T.98]	6856.6	1203.0	5.6997	0.0000	4496.8	9216.3

In []: %stata xtreg milk cows land labor i.year, re

Después de ver los resultados del test de Hausmann nos hemos quedado con el modelo de efectos aleatorios (RE). Esto indica que los efectos específicos de las granjas no parecen estar correlacionadas con las variables independientes. Seguramente esto tiene que ver con que todas las granjas se ubican en el norte de España y comparten características similares como el tiempo, el tipo de hierba, y la comida. Estas similitudes pueden reducir la heterogeneidad no observada entre las granjas, haciendo que las diferencias específicas no estén dentro de nuestro modelo. El modelo de efectos aleatorios (RE) es el mejor para este análisis.

Series Temporales

```
In [ ]: %stata tsset farm year
```

```
Panel variable: farm (strongly balanced)
Time variable: year, 93 to 98
Delta: 1 unit
```

```
In [ ]: %stata gen L1_cows = L.cows
%stata gen L2_cows = L2.cows
%stata gen L3_cows = L3.cows
%stata gen L4_cows = L4.cows
```

```
(247 missing values generated)
(494 missing values generated)
(741 missing values generated)
(988 missing values generated)
```

```
In [ ]: %stata correlate milk L1_cows L2_cows L3_cows L4_cows
```

```
(obs=494)
```

	milk	L1_cows	L2_cows	L3_cows	L4_cows
milk	1.0000				
L1_cows	0.9267	1.0000			
L2_cows	0.9092	0.9764	1.0000		
L3_cows	0.8898	0.9607	0.9821	1.0000	
L4_cows	0.8615	0.9382	0.9633	0.9770	1.0000

Los resultados muestran que los lags de cows están bastante correlacionados con la variable milk, lo cual sugiere que hay una relación entre la producción de leche y los lags de las vacas.

```
In [ ]: %stata reg milk L1_cows L2_cows L3_cows L4_cows
```

Source	SS	df	MS	Number of obs	=	494
Model	5.1042e+12	4	1.2760e+12	F(4, 489)	=	759.05
Residual	8.2206e+11	489	1.6811e+09	Prob > F	=	0.0000
Total	5.9262e+12	493	1.2021e+10	R-squared	=	0.8613
				Adj R-squared	=	0.8601
				Root MSE	=	41001

milk	Coefficient	Std. err.	t	P> t	[95% conf. interval]
L1_cows	7783.1	739.9378	10.52	0.000	6329.251 9236.95
L2_cows	2480.868	1158.843	2.14	0.033	203.9413 4757.795
L3_cows	375.027	1201.02	0.31	0.755	-1984.769 2734.823
L4_cows	-2076.562	887.4636	-2.34	0.020	-3820.274 -332.8492
_cons	-47768.03	4239.328	-11.27	0.000	-56097.58 -39438.48

Coefficientes y significancia:

L1_cows: Coeficiente de 7783.1, $t = 10.52$, $p\text{-value} < 0.001$, lo que indica que el lag de 1 año de cows tiene un impacto significativo en la producción de leche.
L2_cows: Coeficiente de 2480.86, $t = 2.14$, $p\text{-value} = 0.033$, indica que el lag de 2 años de cows también es significativo, aunque con una significancia algo menor.
L3_cows: Coeficiente de 375.027, $t = 0.31$, $p\text{-value} = 0.755$, el lag de 3 años no es significativo.
L4_cows: Coeficiente de -2076.56, $t = -2.34$, $p\text{-value} = 0.020$, el lag de 4 años es significativo.

R-cuadrado: nuestro 0.8613 sugiere que aproximadamente el 86.13% de la variabilidad en la producción de leche (milk) es explicada por los lags de cows. $\text{Prob} > F = 0.0000$ indica que el modelo es significativo en general.

Los lags de cows de 1, 2 y 4 años son significativos para predecir la producción de leche. El lag 3 no parece tener un impacto significativo en la predicción de la producción de leche.

Bibliografía

Datos

[Documentación PyStata](#)

[Documentación NumPy](#)

[Documentación Pandas](#)

[Documentación LinearModels \(PanelOLS, RandomEffects\)](#)

[Documentación SciPy Stats](#)