

Correlaciones en portfollio agrícola evaluado con simulación Monte Carlo

Ariadna M. Berger⁽¹⁻³⁾ y Susana Pena de Ladaga⁽¹⁻²⁾

1-AplicAR: Educación en Administración Rural - Avelino Díaz 2547, 1406 Ciudad Autónoma de Buenos Aires, Argentina.

www.aplicareducación.com; aberber@agro.uba.ar

2-Facultad de Agronomía (Universidad de Buenos Aires) - Avda. San Martín 4453, 1417 Ciudad Autónoma de Buenos Aires, Argentina. UBACYT 20020190100087BA.

spena@agro.uba.ar; www.aplicareducación.com

3-Universidad del CEMA. Córdoba 374, 1054, Ciudad Autónoma de Buenos Aires, Argentina.

Resumen: Se evaluó el efecto del uso de coeficientes de correlación, tanto entre los precios de los granos como entre los rendimientos de los cultivos, en las estimaciones de resultados y riesgos asociados de un portfollio evaluado con un modelo de Simulación Monte Carlo. El portfollio diversificado está integrado por trigo, maíz, girasol, soja de primera y segunda siembra. El módulo considerado fue de 1.000 hectáreas. Los coeficientes de correlación de rendimientos se obtuvieron de series elaboradas con modelos de simulación agronómica; los de precios a partir de series históricas de 12 años (campañas 2007/08 a 2018/19) expresados en dólares estadounidenses constantes, previamente homogeneizados respecto a las retenciones y/o derechos de exportación. Se aplicaron los impuestos vigentes a mayo de 2019 (28% en soja, y 10% en girasol, maíz y trigo). La inclusión de los coeficientes de correlación en el modelo de portfollio elegido no modifica el resultado esperado (se trata de un modelo aditivo). Respecto a la variabilidad, hay un leve aumento en la misma. Se concluye que es importante evaluar un portfollio de estas características incluyendo la correlación entre variables, con el fin de no subestimar el riesgo al cual se enfrenta el productor.

Palabras claves: Correlaciones, decisiones, riesgo, portfollio, agricultura.

1 Introducción

En un trabajo anterior del grupo de trabajo [1] se concluyó que al incluir correlaciones (de medianas a altas), no se observaban cambios significativos en los resultados medios. Sí hubo modificaciones en cuanto a las medidas de variabilidad, así como también en las características de las distribuciones de resultados. Los “resultados reales” son sin duda los que incluyen las correlaciones. En estos casos pudo observarse que, para la misma combinación de actividades, al incluir las correlaciones se estima un riesgo de mayor magnitud (se amplía el ancho de la campana por la mayor dispersión de los resultados). La falta de correlaciones en el modelo da lugar a posibilidades de compensación entre variables que en la realidad no existen, porque las correlaciones existentes son de nulas a positivas. El método de Simulación Monte Carlo permite contemplar, y en consecuencia evaluar y comparar, su efecto de modo más preciso. Se trata de una herramienta que ha tenido amplia difusión por la sencillez de interpretación de sus resultados; sin embargo, en la práctica no siempre se tienen en cuenta las correlaciones. Se aconsejó por ello la inclusión de correlaciones, dado que a priori es muy difícil poder vislumbrar su efecto: no es algo que puede determinarse en forma intuitiva.

2 Materiales y Métodos

En esta ocasión, además de tener en cuenta la correlación de rendimiento entre cultivos y precios, se consideraron dos tipos de suelos con distinta capacidad productiva, lo cual da lugar a más correlaciones, motivadas en los diferenciales por este factor. Se trabajó con un modelo representativo de la zona de Gral. Villegas, tomando un módulo de 1.000 ha (de las cuales 816 son agrícolas) para facilitar la extrapolación de resultados. El 19% de la superficie agrícola se destina a trigo/soja de segunda, 15% a maíz, 54 % a soja de primera y 12% a girasol. El uso de correlaciones se analizó considerando 4 escenarios: la totalidad de la superficie con soja de primera siembra, el porfolio óptimo surgido de la optimización con programación lineal (PL) [2], el típico con rotación diversificada que corresponde al promedio de 10 años del partido, antes del auge de la soja (campañas 1995/96 a 2005/6) con la finalidad de que el porfolio sea diversificado -el óptimo económico desde 2015 a la actualidad se logra con la totalidad de trigo/soja de segunda- [2] y el que surge de buscar el máximo de los mínimos mediante optimización estocástica [3]. En ninguno de los casos el modelo incluye el costo de arrendamiento, es decir que evalúa el caso de un productor propietario. Para la comparación se utilizó el método de simulación Monte Carlo (SMC) que permite describir el comportamiento de una variable (que a su vez depende de otras variables aleatorias) dados los posibles valores de éstas. A diferencia de otras técnicas del mismo grupo, la SMC se basa en la aleatorización de los valores usados para las variables que definen el modelo y permite trabajar de manera simple con gran cantidad de variables inciertas, que responden a diferentes funciones de probabilidad, en modelos que pueden representar sistemas complejos [4]. La concientización acerca de las diversas fuentes de riesgo actuantes sobre el sector agropecuario [5]; [6]; [7]; [8]; [9]) constituye el factor fundamental por el que este método extiende su uso desde la

difusión de software de sencillo manejo. Las variables aleatorias consideradas fueron modelizadas con distribuciones Pert. El software utilizado fue Risk Simulator [10] y el número de iteraciones fue de 5.000 con número semilla 1. Los márgenes brutos se trabajaron en dólares constantes. Los insumos se valuaron a precios de la campaña 2017/2018, extraídos de la revista Márgenes Agropecuarios a la siembra de cada cultivo. Los planteos técnicos fueron ajustados por expertos. Los rendimientos fueron extraídos de la base de datos RindEs [11] para trigo, soja de primera y segunda siembra y maíz. En el caso de girasol, no incluido en dicha base de datos, la información se obtuvo de expertos de la zona. Están separados por ambiente, considerando los suelos de Loma, que son los de mejor calidad, y los de Plano Alto, con menores rendimientos debido a sus características. Se extractaron los valores de los percentiles 5% y 95% para utilizar como valores mínimos y máximos respectivamente diferenciando entre el ambiente de loma (con suelos de capacidad de uso I, del ambiente de plano alto, donde la capacidad de uso es III). Los mismos se observan en la Tabla 1.

Tabla 1: Distribuciones de rendimiento de cultivos por ambiente (toneladas/ha)

RINDE (TN/HA)	RTL	RS1 L	RS2 L	MRL	RG L
Ambiente Loma					
MINIMO	2,815	1,882	1,694	2,235	2,300
MAS PROBABLE	4,492	3,498	3,523	7,972	2,500
MAXIMO	5,759	5,605	4,369	9,679	3,000
Esperado	4,42	3,58	3,36	7,30	2,55
Ambiente Plano alto					
MINIMO	0,94	1,763	1,349	0,292	1,955
MAS PROBABLE	3,559	3,612	3,17	7,503	2,125
MAXIMO	5,441	5,194	4,276	9,313	2,55
Esperado Pert	3,44	3,57	3,05	6,60	2,17
PRECIO (u\$s/TN)	PRT	PR S1	PR S2	PR M	PR G
Ambiente plano alto					
MINIMO	150,13	284,16	284,16	132,67	278,67
MAS PROBABLE	212,79	408,19	408,19	184,85	385,53
MAXIMO	339,97	514,11	514,11	254,36	502,75
Esperado Pert	223,54	405,17	405,17	187,74	387,26

Fuente: [11]. Girasol: opinión de expertos.

En cuanto a los precios al ser dependientes de los valores internacionales que, a su vez, están influenciados por múltiples factores [12], se trabajó partiendo de series históricas de 12 años (campañas 2007/08 a 2018/19) del mercado de Chicago, en dólares estadounidenses constantes a mayo de 2019, previamente homogeneizados respecto a retenciones y /o derechos de exportación (Tabla 2). A estos valores se le aplicaron los impuestos vigentes a mayo de 2019 (28% en soja, y 10% en girasol, maíz y trigo).

Tabla 2: Precios de granos en dólares constantes a mayo de 2019 descontadas retenciones (US\$/tonelada)

	Trigo	Soja	Maíz	Girasol
Mínimo	135,12	204,60	119,40	250,80
Más probable	191,51	239,90	166,36	346,98
Máximo	305,97	370,16	229,92	452,75
Esperado	201,19	291,72	168,96	348,53

Fuente: Elaboración propia.

Respecto a las correlaciones, se calculó el coeficiente de Spearman (o por orden de rangos) ya que el de Pearson (más usual) no está diseñado para medir correlación en distribuciones no lineales y/o con distribuciones no normales, que usualmente se presentan en los casos utilizados [5]; [6]; [4]. Los coeficientes de correlación entre rendimientos de los dos ambientes considerados se resumen en la Tabla 3, donde se vislumbra una correlación mayoritariamente positiva, elevada entre cultivos de cosecha gruesa, de modo tal que, cuando las condiciones meteorológicas son buenas, los cultivos estivales tienen mayor rendimiento. Del mismo modo son elevadas cuando se trata del mismo cultivo en suelos diferentes, dado que las condiciones meteorológicas actúan del mismo modo en los dos tipos de suelo con el mismo cultivo. Sólo el trigo y la soja de segunda tienen una leve correlación inversa, que fue incluida en el modelo, a pesar de estar debajo de un valor absoluto de 0,3 y que, según lo que [4] menciona, podría no tenerse en cuenta.

Tabla 3: Coeficientes de correlación de Spearman entre rendimientos

		TRIGO	SOJA 1	SOJA 2	MAIZ	GIRASOL	TRIGO	SOJA 1	SOJA 2	MAIZ	GIRASOL
		LOMA	LOMA	LOMA	LOMA	LOMA	P. ALTO	P. ALTO	P. ALTO	P. ALTO	P. ALTO
RT L	LOMA	1	-0,04	-0,28	0,22		0,97	-0,1	-0,2	0,28	
RS1 L	LOMA		1	0,7	0,81	0,5	-0,05	0,91	0,7	0,77	
RS2 L	LOMA			1	0,32	0,3	-0,3	0,86	0,99	0,29	
RM L	LOMA				1	0,3	0,21	0,66	0,33	0,98	
RG L	LOMA					1					
RT PA	PLANO ALTO						1	-0,11	-0,2	0,25	0,5
RS1 PA	PLANO ALTO							1	0,86	0,61	0,3
RS2 PA	PLANO ALTO								1	0,3	0,3
RM PA	PLANO ALTO									1	
RG PA	PLANO ALTO										1

Fuente: Elaboración propia.

Para el caso de los precios, las correlaciones (también de Spearman) se observan en la Tabla 4; en todos los casos son positivas y elevadas y muestran lo que se ve en la práctica: los precios de los commodities están todos altos, o están todos bajos.

Tabla 4: Coeficientes de correlación de Spearman entre precios

	Trigo	Soja	Maíz	Girasol
Trigo	1	0,50	0,76	0,37
Soja		1	0,66	0,77
Maíz			1	0,62
Girasol				1

Las correlaciones entre variables deben tener un factor causal; al no poder influenciar el rendimiento de un establecimiento en los precios internacionales, ni tampoco estos últimos actuar sobre las condiciones meteorológicas que determinan el rendimiento, no se consideró correlación entre estas dos variables [12].

3 Resultados y Discusión

A continuación, se presentan los resultados de los parámetros comparados sin y con aplicación de las correlaciones (Tabla 5). Puede observarse que los resultados, casi similares en las cifras medias, difieren en cambio en aquellos parámetros que miden la variabilidad (desvío estándar, coeficiente de variación, máximos, mínimos y rangos). En el caso del monocultivo de soja, las medias son casi idénticas, pero incluyendo las correlaciones se obtiene un desvío mayor porque la correlación entre los rendimientos de los dos tipos de suelos es muy alta. El mayor desvío conlleva a un mayor coeficiente de variación, de 28,16% a 31,16%.

Tabla 5: Parámetros de SMC SIN incluir correlaciones

	SIN	CON	SIN	CON	SIN	CON	SIN	CON
	SOJA IRA.		OPTIMO		TIPICO		MIN.DESVIO	
Número de Pruebas	5.000	5.000	5000	5000	5000	5000	5000	5.000,00
Media	679.660	679.664	838.363	838.264	608.066	608.102	351.943	351.600
Mediana	675.104	662.705	831.628	831.404	604.159	598.383	349.971	350.924
Desviación Estándar	191.361.83	211.786	194.549	225.718	128.873	166.487	64.749	69.293
Variación	36.619.351.105	44.853.358.670	37.849.466.137	50.948.654.967	16.608.361.380	27.717.983.124	4.192.447.705	4.801.498.100
Coeficiente de Variación	28,16%	31,16%	23,21%	26,93%	21,19%	27,38%	18,40%	19,71%
Máximo	1.386.631	1.368.837	1.602.198	1.609.527	1.029.742	1.157.033	560.969	561.606
Mínimo	127.573	108.690	264.761	110.732	233.065	84.040	179.835	162.965
Rango	1.259.058	1.260.147	1.337.437	1.498.794	796.677	1.072.992	381.134	398.641
Asimetría	0,20	0,28	0,1084	0,1510	0,0905	0,20	0,1122	0,06
Curtois	0,17	0,21	-0,1161	-0,2148	-0,2038	0,23	-0,5606	0,51
Percentil 25%	542.627	529.723	704.379	679.206	517.207	490.522	304.447	300.749
Percentil 75%	807.250	819.632	967.747	990.821	695.781	721.147	399.346	401.410
Precisión de Error 95%	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Es decir, se confirma que la inclusión de las correlaciones da como resultado una curva con mayor amplitud, que está representando un mayor riesgo. Si bien en los modelos aditivos no hay cambios en las medidas centrales, las variaciones representa-

tivas del riesgo muy posiblemente influirían en las decisiones del productor, optando por una de las otras combinaciones de cultivos, o aplicando la medidas correspondientes para prevenir el riesgo a asumir; todo es dependiente de la actitud personal hacia el riesgo.

4 Conclusiones

La inclusión de los coeficientes de correlación produce efectos de consideración en los parámetros indicadores de riesgo. Por tal motivo, no deberían dejarse de incluir en los modelos ya que, como asesores, estaríamos induciendo a tomar decisiones erróneas. Si bien esto confirma algo que insistentemente se ve en la bibliografía, es bastante gráfico el ejemplo comparativo de un único tipo de suelo y de la subdivisión en dos categorías para reafirmar y profundizar la temática de las correlaciones.

Referencias:

1. Berger, A.; Pena de Ladaga, S. (2022). Correlaciones: ¿el uso de coeficientes de correlación afecta los resultados de un modelo de portfolio agrícola evaluado con simulación Monte Carlo? III Seminario de Gestión del riesgo agropecuario. Facultad de Ciencias Económicas, 28 al 30 de septiembre de 2022, Universidad de Buenos Aires, Argentina.
2. Pena de Ladaga, S.; Marra, R.; Ladaga, B.; Sanguinetti, J. (2015). Diversificación y retenciones: análisis mediante un modelo de decisión optimizante. IX Jornadas de Estudios Agrarios y Agroindustriales latinoamericanos. Eje temático: 7: La sojización, aspectos sociales, económicos y ambientales. Facultad de Ciencias Económicas – UBA, 2 al 4 de noviembre 2015.
3. Pena de Ladaga y Berger, 2019. Optimización estocástica: análisis de ejemplo sencillo para detectar ventajas e inconvenientes en la metodología. Actas de la L Reunión de la Asociación Argentina de Economía Agraria; 1 al 5 de noviembre, Facultad de Agronomía de la Universidad de Buenos Aires. Eje temático: Programación matemática. Investigación operativa.
4. Vose, D. (2008). Risk Analysis. A quantitative guide. 3rd. Edition. John Wiley & Sons, Ltd. 734 p.
5. Berger y Pena de Ladaga, 2016. Decisiones riesgosas en empresas agropecuarias. Simulación Monte Carlo como herramienta para el productor y el asesor. 2da. Edición corregida y ampliada. Editorial Orientación Gráfica Editora. ISBN 978-987-1922-17-8. 120 p.
6. Pena de Ladaga y Berger, 2006. Toma de decisiones en el sector agropecuario: Herramientas de Investigación Operativa aplicadas al agro. Editorial Facultad de Agronomía. 308 p. ISBN 978-950-29-0925-7 308 p.
7. Harwood, J.; R. Heifner; K. Coble; J. Perry and A. Somwaru. 1999. Managing risk in Farming: Concepts, Research and Analysis. Agricultural Economic Report 744. Economic Research Service, USDA. 125 p.
8. Stratta, J. 2001. Administración del riesgo: seguros para el sector agrícola en la Argentina. Departamento de Capacitación y Desarrollo de Mercados. Bolsa de Comercio de Rosario. 15 p.
9. Hardaker, J.B.; Huirne, R.B.M.; Anderson, J.R. (2015). Coping with risk in agriculture. Researchgate.net/profile/Jock_Anderson/publication/26446444532.
10. Real Options Valuation Inc. (2022). Comercializado por Software Shop.
11. Cultivar Conocimiento Agropecuario S. A., 2019. www.cultivaragro.com.ar/rindes

12. Boussard, J. M. 2015. El riesgo en las decisiones de la producción agropecuaria: aspectos microeconómicos. *En*: «Notas sobre economía de la agricultura y las empresas agropecuarias y agroindustriales». Editora: Carmen Vicién. Orientación Gráfica Editora. Buenos Aires p. 15-58.