

A new AI-based similarity measure for recommending optimal long-term crop rotation alternatives

Lucía Pedraza^{1,2}, Diego Ferraro¹, Felipe Ghersa¹ and Rodrigo Castro²

¹ Universidad de Buenos Aires (UBA), FAUBA, Cátedra de Cerealicultura. UBA-CONICET, Instituto de Investigaciones Fisiológicas y Ecológicas Vinculadas a la Agricultura (IFEVA)
² Universidad de Buenos Aires (UBA), Facultad de Ciencias Exactas y Naturales, Departamento de Computación. CONICET, Instituto de Ciencias de la Computación (ICC)
lupipedraza@gmail.com

Abstract. We present a tool that enables personalized recommendations for agricultural producers by offering long-term crop rotation alternatives that simultaneously optimize economic and environmental efficiency across multiple variables. To achieve this, we propose a new similarity metric between sequences of agronomic decisions, based on neural network techniques commonly used in the field of natural language processing. This metric allows us to select, from a set of Pareto-optimal solutions (generated by the AgrOptim simulation and optimization system), those sequences that are most similar to the typical and customary practices of each producer. In this way, we aim to reduce the barriers to adopting the recommendations generated by AgrOptim, facilitating the implementation of more sustainable and efficient cropping sequences and production decisions.

Keywords: Crop Rotation, Optimization, Similarity Metrics.

Una nueva medida de similitud basada en IA para recomendación de alternativas óptimas de rotaciones agrícolas a largo plazo

Resumen: Presentamos una herramienta que permite realizar recomendaciones personalizadas a productores agrícolas, ofreciendo alternativas de rotaciones de cultivos a largo plazo que optimicen simultáneamente la eficiencia económica y ambiental considerada en múltiples variables. Para ello, proponemos una nueva métrica de similitud entre secuencias de decisiones agronómicas, basada en técnicas de redes neuronales utilizadas en la disciplina del procesamiento de lenguaje natural. Esta métrica permite seleccionar, dentro de un conjunto de soluciones óptimas en sentido de Pareto (obtenidas por el sistema de simulación y optimización AgrOptim) aquellas secuencias más similares a las prácticas típicas y usuales de cada productor. De este modo, se busca minimizar las barreras de adopción de recomendaciones generadas por AgrOptim, facilitando la puesta en práctica de secuencias de cultivo y decisiones productivas más sostenibles y eficientes.

Palabras clave: Rotación de Cultivos, Optimización, Métricas de Similitud

1 Introducción

Los productores agrícolas toman cada año decisiones estratégicas para optimizar sus ganancias y la eficiencia del uso de sus recursos. Aspectos como el uso del suelo, el nivel tecnológico, o la fecha de siembra son ajustados en un contexto que involucra variables económicas, climáticas y de sitio. Como consecuencia, dicha optimización requiere un enfoque multiobjetivo que combina la rentabilidad económica junto a múltiples aspectos ambientales (Colnago et. al., 2021).

Recientemente se desarrolló AgrOptim (Ghersa et. al., 2024), una herramienta que combina simulación con optimización para encontrar secuencias óptimas de decisiones agronómicas a lo largo de varios años. Dado el carácter multidimensional del problema, los resultados óptimos no son únicos sino que pertenecen a una frontera de Pareto, es decir, el conjunto de secuencias de decisiones agronómicas cuyos indicadores resultantes no pueden mejorarse en una variable sin empeorar en otros.

Sin embargo, para poder recomendar una secuencia tomada del conjunto de opciones dentro de la frontera de Pareto, es necesario establecer algún un criterio robusto que facilite su selección. Nos interesa especialmente identificar el subconjunto de decisiones con mayor posibilidad de ser adoptadas por un productor dado y que por lo tanto no impliquen cambios drásticos en sus prácticas agronómicas usuales. El objetivo general de este trabajo es evaluar la similitud entre decisiones agronómicas (rotaciones de cultivos) como insumo para una posterior selección de alternativas Pareto-óptimas en el uso de los recursos, pero que simultáneamente impliquen un menor esfuerzo en términos de los cambios de decisiones requeridos para su implementación. Para ello proponemos el uso de una nueva métrica basada en técnicas de Inteligencia Artificial, en particular la técnica word2vec (Mikolov et. al., 2013) de procesamiento de lenguaje natural (NLP).

2 Definición de Rotaciones: Decisiones (D)

Las decisiones que toma un productor agrícola se dan en un contexto que involucra variables económicas, climáticas y de sitio que pueden ser predecibles o pronosticadas con distinto grado de error. Si bien esas decisiones pueden ser muy variadas, para modelar y poder establecer distancias y similitudes consideraremos solamente un conjunto finito de opciones determinadas por la distintas elecciones que pueden realizarse cada campaña. En cada año consideraremos que cada productor podrá solamente decidir sobre 4 aspectos:

- El uso del suelo: Indica el cultivo principal sembrado durante el año (campaña). Teniendo en cuenta los cultivos utilizados en la zona tomamos como opción solamente cultivos de soja, maíz, girasol y trigo o doble cultivos compuestos por trigo (como cultivo invernal) y soja o maíz como cultivos de segunda.
- El cultivo de cobertura: Entre los cultivos de cada año se puede realizar un barbecho o un cultivo de cobertura que puede ser vicia o centeno.
- La ventana de siembra del cultivo: Se indica si el cultivo fue sembrado como temprano o tardío (los cultivos de segunda definen su siembra con la cosecha del cultivo de primera). Para simplificar la cantidad de opciones no incorporamos este elemento en el análisis.

- El nivel tecnológico utilizado: Representa la capacidad del productor agrícola de intensificar su producción a partir del uso creciente de insumos. En nuestro trabajo este gradiente se representa por la intensidad de uso de fitosanitarios y el nivel de fertilización utilizado en cada cultivo. Los niveles pueden ser bajo, medio o alto.

En total, obtenemos un vector de dimensión 12, donde cada componente representa un año y en cada año se listan los cuatro elementos elegidos entre los listados arriba. En la Fig. 1 se pueden observar tres secuencias distintas: La rotación clásica de tercios en la que se alternan maíz, soja y trigo/soja de segunda; la secuencia dentro del conjunto pareto-óptimo que minimiza la distancia a la rotación de tercios; y un monocultivo de trigo. Cada año está representado por un cuadrado. Tanto el color como la letra representan el cultivo de esa campaña, que puede ser un cultivo de primera (representado por un solo color), o un doble cultivo compuesto por un cultivo de primera y otro de segunda (representado por dos triángulos). El rectángulo vertical señala el barbecho o cultivo de cobertura realizado ese año. La barra blanca vertical representa la ventana de siembra de siembra del primer cultivo: si aparece antes de la letra corresponde a una siembra temprana; si está después es tardía. Finalmente, el punto en la esquina superior izquierda del cuadrado representa el nivel tecnológico utilizado ese año.

A la derecha de la figura se observa el resultado simulado en las 5 variables consideradas: La rentabilidad, el radio de energía renovable (ELR), la eficiencia en el uso de la precipitación (yppm), la toxicidad para insectos (UTins) y el aporte de carbono. Cuanto más grande sea el área del polígono mejor optimizadas estarán las variables.

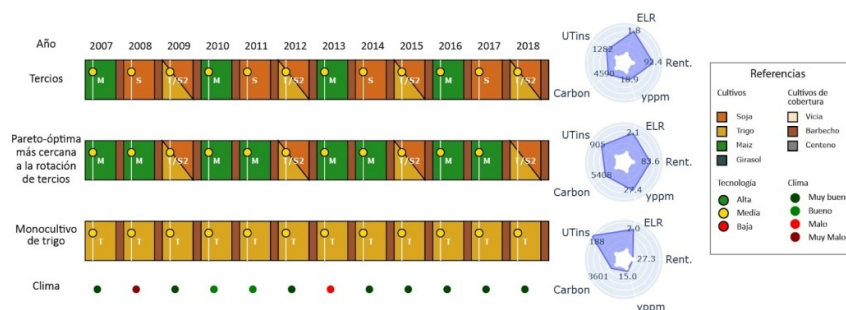


Fig. 1. (A la izquierda) Se muestran tres secuencias de rotaciones distintas: La rotación clásica de tercios, la solución pareto-óptima más cercana a la rotación de tercios y un monocultivo de trigo. (A la derecha) Se ven los resultados de las respectivas decisiones en suelo y un contexto climático determinado.

3 Cálculo de Brechas

El objetivo de este trabajo es establecer una métrica en el espacio de posibles decisiones. Una métrica es una función que toma dos elementos de un conjunto y devuelve

un número real positivo que indica la distancia entre ambos. Para que la métrica propuesta sea indicativa debe cumplir que para secuencias parecidas las distancias resultantes deberán ser pequeñas, mientras que para secuencias distintas las distancias serán grandes.

Una posibilidad es comparar las decisiones tomadas en cada año, penalizando aquellos años donde las decisiones sean distintas, es decir, utilizar la distancia de Hamming. Sin embargo esto trae algunos problemas. Dos decisiones anuales pueden ser distintas solo por ser diferir en un elemento no tan importante, pero ser muy similares en la práctica. Por ejemplo, dos decisiones anuales que tienen el mismo cultivo, el mismo cultivo de cobertura y el mismo nivel tecnológico pero fechas de siembra distintas no deberían penalizarse tanto como dos campañas donde se plantan cultivos distintos. Esto nos lleva a la necesidad de establecer una distancia entre decisiones anuales que puedan dar cuenta de estas diferencias.

Para ello proponemos el uso de una nueva métrica basada en técnicas de Inteligencia Artificial, en particular la técnica word2vec de procesamiento de lenguaje natural (NLP). En los modelos word2vec cada palabra se representa mediante un vector en un espacio n-dimensional, donde las palabras con significados similares se encuentran más próximas entre sí medidas con la distancia del coseno. La idea central es que el significado de una palabra está determinado por su contexto, es decir, por las palabras que la rodean. Para obtener estos vectores se utilizan modelos de redes neuronales para aprender asociaciones de palabras a partir de grandes volúmenes de datos de textos. La arquitectura de estas redes neuronales puede ser un modelo tipo bolsa de palabras continuo (CBOW) o skip-gram continuo.

En el contexto de las rotaciones agronómicas, consideramos que una secuencia de decisiones a lo largo de los años puede representarse como una "oración", donde cada "palabra" corresponde a una decisión anual.

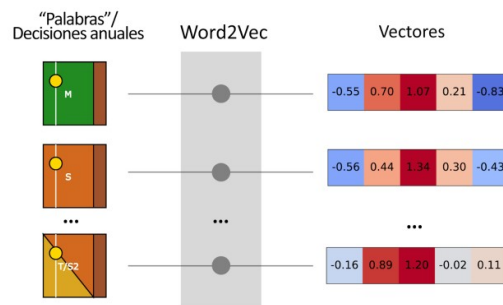


Fig 2: Esquema del proceso de entrenamiento con word2vec.

Entrenamos este modelo utilizando como corpus de entrenamiento las secuencias óptimas calculadas por AgrOptim. Asumimos que dos decisiones anuales van a ser "similares" si las decisiones que se tomaron en los años anteriores y posteriores fueron las mismas para una gran cantidad de secuencias optimizadas. De esta manera el modelo nos devolverá un conjunto de vectores, donde cada vector representa una posible decisión anual. Aquellas decisiones similares deberán estar cerca con la distancia del coseno. El esquema del proceso de entrenamiento se muestra en la Fig. 2.

Por último, para calcular las brechas entre secuencias promediamos la distancia cuadrática de los doce años. Es decir, dada la distancias entre decisiones anuales d_p , definimos la distancia entre dos decisiones D_1 y D_2 como

$$d(D_1, D_2) = \sqrt{\frac{1}{12} \sum_{i=1}^{12} d_p(D_1(i), D_2(i))^2}. \quad (1)$$

De esta manera obtenemos un valor de distancia entre cada par de secuencias donde el valor será mayor cuando mayor variación haya año a año.

Las métricas de similitud fueron desarrolladas utilizando *Word2Vec* de la biblioteca *Gensim* en *Python*. Se entrenó sobre las secuencias de decisiones pertenecientes a la frontera de Pareto generada por el sistema *AgrOptim* (Ghersa et. al., 2024). Este framework utiliza un enfoque orientado a objetos e implementa algoritmos genéticos mediante el framework *DEAP* (Distributed Evolutionary Algorithms in *Python*) para encontrar soluciones óptimas. Por último, se desarrolló una interfaz gráfica utilizando el framework *Dash* de la librería *Plotly* para ofrecer recomendaciones que minimicen la métrica propuesta. Estos módulos se integran de forma secuencial: *AgrOptim* genera las secuencias óptimas, el modelo *Word2Vec* aprende representaciones vectoriales, y la interfaz visual permite seleccionar las opciones más similares a las prácticas del productor.

4 Conclusiones

Utilizando la métrica propuesta podemos calcular la distancia a una rotación determinada a todas las secuencias pareto-óptimas obtenidas en ese contexto particular. En la Fig. 1, por ejemplo, se muestra la rotación clásica de tercios y la rotación pareto-óptima que minimiza la distancia (con distancia $d=0.03$). Las comparamos además con una rotación con una distancia mayor: un monocultivo de trigo (con distancia $d=0.64$).

De esta manera podemos utilizar esta herramienta para ofrecer como alternativa a una rotación específica, la rotación optimizada que minimiza la distancia. Esto minimizará los costos de adopción, favoreciendo la puesta en práctica de rotaciones más eficientes y sostenibles.

Referencias

Colnago, P., Rossing, W. A. H., & Dogliotti, S. (2021). Closing sustainability gaps on family farms: Combining on-farm co-innovation and model-based explorations. *Agricultural Systems*, 188, 103017.

Ghersa, F., Figarola, L. A., Castro, R., Ferraro, D. O. (2024). *AgrOptim*: A novel multi-objective simulation optimization framework for extensive cropping systems. *Computers and Electronics in Agriculture*, 224, 109119.

Mikolov T., Chen K., Corrado G., Dean J. (2013). Efficient estimation of word representations in vector space. arXiv preprint arXiv:13013781.