

ESTIMADOS DE PRODUCCIÓN DE CAÑA DE AZÚCAR (*Saccharum spp.*) UTILIZANDO UN MÉTODO BIOFÍSICO.

*Kim Young*¹; *Gómez J. Israel*²; *Jimenez Marco*³

1 CEO Digital Harvest

2 Digital Harvest

3 Gerente de Marketing Valent de México

RESUMEN

El pronóstico de producción en el cultivo de caña de azúcar se realiza generalmente 2 meses antes del comienzo del período de zafra. Esto implica que las estimaciones de producción se harán en plantaciones que se cosecharán de 2 a 8 meses después. Consecuentemente, existe un error estacional promedio de 10% a nivel de zona de abastecimiento de un ingenio. Este error asciende a valores mayores a nivel de sector o productor. A lo largo de los años, se han diseñado diferentes estrategias de estimación cuantitativa, las cuales se basan principalmente en la experiencia de los supervisores de campo. El desarrollo de un método cuantitativo y escalable que considere las variables de las diferentes áreas de producción ofrece la oportunidad de aumentar la precisión en las estimaciones tanto a nivel de campo como del ingenio. Por tal motivo, se ha diseñado un método utilizando técnicas de aprendizaje automático aplicadas a un modelo biofísico específico para las características de la caña de azúcar. En el mismo, se han considerado datos históricos del suelo, clima, manejo, condiciones fitosanitarias, nutrición y resultados de producción. La integración de estos datos a los obtenidos de sensores remotos, incluyendo datos espectrales de los cultivos, y modelos calibrados derivados de antecedentes y pronósticos de clima permiten que un único modelo pueda aprovechar información valiosa de operaciones independientes relacionadas con la caña de azúcar como así también, datos específicos a nivel regional. Los modelos entrenados describen una relación cuantitativa entre factores independientes y los resultados de producción. Su primera aplicación consiste en mejorar las estimaciones operacionales mediante la predicción de la producción bajo el plan existente. Esta metodología está siendo empleada desde hace 5 años en 80.000 hectáreas en Florida, Estados Unidos. La predicción de la zafra 2016/2017 mostró que el error se redujo del 10.3% al 1.57%. El estudio retrospectivo de zafras utilizando esta metodología mostró que el error se redujo de 10%-15% a menos del 3% para los 10 años comprendidos entre 2006 y 2016. Por otro lado, los resultados de producción pueden ser simulados ajustando las variables ingresadas para permitir nuevos tipos de análisis. Este método ha sido implementado para simular posibles fechas de cosecha, y optimizar así el calendario estacional de cosecha para obtener resultados máximos en los cultivos del 2019, con una mejora estimada en la producción del 2%.

SUGAR CANE PRODUCTION ESTIMATES (*Saccharum spp.*) USING A BIOPHYSICAL MODEL

Kim Young¹ ; Gómez J. Israel²; Jimenez Marco³

1 CEO Digital Harvest

2 Digital Harvest

3 Gerente de Marketing Valent de México

ABSTRACT

The forecast of production in sugarcane cultivation is typically made 2 months before the beginning of the harvest season for all fields to be harvested between 2 and 8 months later. At the mill level, mean seasonal error in these estimates is approximately 10%, but at the level of an individual sector, producer, or field, error is much higher. While quantitative yield estimation strategies are used yield estimates mostly rely on the experience and familiarity of field supervisors. A scalable quantitative method that is able to account for the many variables spread across many management areas offers an opportunity to increase predictive accuracy at every level, from the field up to the mill. Such a method has been devised with machine learning techniques on sugarcane specific biophysically modeled features, built from raw data about soil, weather, climate, management, physiological conditions, nutrition, and yield outcomes. Globally scalable data streams including spectral data about crop canopies, gridded and ground calibrated weather and climate histories and forecasts allow a single machine learner to leverage data insights from many separate sugarcane operations, with additional regionally specific data as added value. Trained models represent a quantitative relationship between input factors and yield outcomes. The first application of this capability is to improve operational estimates by simply predicting yield under an existing plan. This method has been employed for 5 years on 80,000 hectares of sugarcane land in Florida, United States. Seasonal backtesting shows a reduction in error from 10 to 15% to less than 3% for the 10 years between 2006 and 2016. In a live 2016-2017 prediction, error was reduced from 10.3% to 1.57%. However, yield outcomes can be virtually experimented with by adjusting input variables under management control to enable new types of analysis. This method has been deployed to simulate multiple harvest date options, and optimize the full seasons harvest schedule for maximum yield outcomes in the 2019 crop year, with an estimated yield improvement of 2%

INTRODUCCIÓN

Determinar con precisión y suficiente anticipación la producción de caña de una zafra es de gran importancia para una eficiente operación tanto de las actividades de cosecha como de las de la fábrica. Esto facilita la predicción de la producción de azúcar, alcohol, energía eléctrica, miel incristalizable, mieles intermedias, bagazo, entre otros, en una zafra determinada, permitiendo una mejor toma de decisiones en cuanto a almacenaje, transporte y comercialización de los productos. En consecuencia, esta correcta predicción posibilita no sólo definir el inicio y terminación óptimos de la zafra, y la capacidad del ingenio para procesar lo estimado sino también establecer programas de derivación o uso alternativo de la caña y de comercialización incluyendo las exportaciones. Otro de los beneficios incluye la realización de programas de recursos de cosecha, por ejemplo cosechadoras, cortadores de caña, equipos de transporte, equipos de alce, machetes, limas, albergues, equipo de protección, y de adquisición de materiales para fábrica, como por ejemplo lubricantes, productos químicos y envases para el azúcar.

A lo largo de los años, varios métodos de estimación se han diseñado. Entre ellos podemos citar

- Método visual que se basa principalmente en la experiencia del supervisor.
- Composición de cepas y precipitación de mayo a octubre, utilizado principalmente en Cuba.
- Método de índices climáticos, del suelo y fisiológicos
- Diagnóstico de rendimientos de caña de azúcar utilizando factores climatológicos múltiples implementado especialmente en Honduras.
- Sistema AquaCrop
- Estimación de productividad en caña de azúcar desde la percepción remota. .
- Caracterización de las lluvias y los suelos y su relación con el rendimiento de campo.

La mayoría de los métodos desarrollados han resultado efectivos dando niveles de confiabilidad considerablemente altos. Sin embargo, estos métodos son altamente laboriosos y por lo tanto, dejan de ser utilizados al no resultar prácticos. En consecuencia, se regresa al método tradicional realizando los estimados en base a la determinación visual y la información que proporcionan los supervisores. Esto trae como consecuencia sobreestimación de algunas plantaciones y subestimación de otras.

Por los motivos expuestos anteriormente surge la necesidad de desarrollar un sistema confiable, oportuno y práctico para realizar los pronósticos de rendimiento de caña como así también, para optimizar el inicio y terminación de la zafra donde las cosechas son máximas.

METODOLOGÍA

El método creado por los científicos de Digital Harvest tiene como base la unidad de manejo del cultivo que podemos llamar campo, parcela, predio, entre otras denominaciones. Como requisito principal, esta unidad de manejo debe ser homogénea en cuanto a variedad, edad y ciclo, como así también debe estar georreferenciada. Se crea un modelo biofísico que no sólo considera el historial de producción, la información climática, precipitación, temperaturas máximas y mínimas, horas luz, condiciones edáficas sino también integra información obtenida de sensores remotos, incluyendo datos espectrales de los

cultivos, y modelos calibrados derivados de antecedentes y pronósticos de clima. Este procedimiento permite que un único modelo pueda aprovechar información valiosa de operaciones independientes relacionadas con la caña de azúcar.

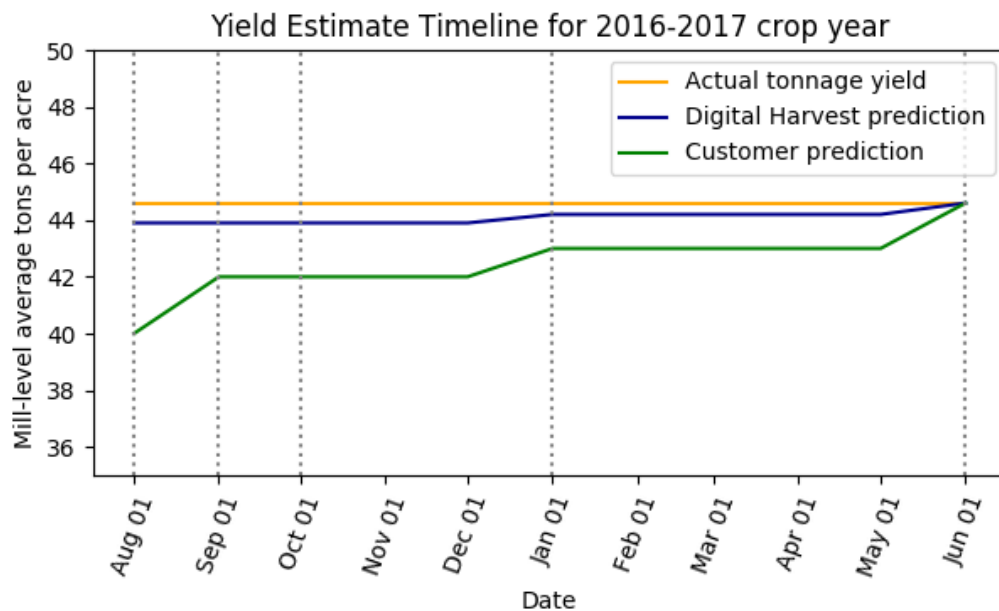
Este método se ha utilizado por primera vez en 2014, en el área cañera del estado de Florida en USA. Para poder predecir el rendimiento de 80,000 hectáreas pertenecientes a la empresa United States Sugar Corporation, se utilizaron datos de producción, clima, manejo, suelos y fisiológicos de 29 años de ese área.

De la misma manera, el modelo de predicción de rendimiento se implementó para simular varias fechas de cosecha y escenarios climáticos posibles para una rotación de cultivo entera con el fin de optimizar el calendario estacional de cosecha y obtener resultados máximos de rendimiento. Cabe destacar que la optimización se realizó a nivel de un campo individual lo que brinda un campo de acción de toma de decisión para la temporada de cosecha activa e impactando también en el rendimiento total potencial de todos los cortes hasta el próximo replante. Las fechas se clasifican para todos los campos, y el proceso de optimización asigna las cosechas en los campos más flexibles lejos de aquellas fechas sobreasignadas a áreas del cronograma con más flexibilidad.

RESULTADOS

El método para la zafra 2016/2017 se aplicó en una primera corrida en el mes de agosto de 2016. Los resultados arrojaron que la estimación realizada por el modelo presenta sólo una variación del 1.57 % en comparación con el resultado final de la zafra. Esto representa una gran mejora si se considera que la estimación hecha por parte del personal técnico de US Sugar Co. se realizó con un 10 % de error en la misma fecha.

Estimaciones similares se hicieron en fechas posteriores más cercanas a la fecha de cosecha. Las predicciones utilizando el método de Digital Harvest presentaron en todos los casos un menor error de estimación a las realizadas por el cliente, como se puede observar en la figura 1.



En los últimos años, las estimaciones en el rendimiento obtenidas por Digital Harvest han influenciado a su vez las predicciones realizadas por los clientes. Esto ha resultado en que las estimaciones de rendimiento de los clientes estén estrechamente relacionadas con la estimación hecha el modelo de Digital Harvest.

En la zafra 2018/2019, un cronograma de optimización de cosecha fue realizado a nivel de campo individual. Pese a que la optimización resulta específica para cada campo y existe una variedad de clases de campos, algunas conclusiones generales resultan obvias del análisis. La zafra en Florida ha empezado históricamente el 1ro de Octubre terminando al final del invierno, y normalmente nunca después de Febrero. Específicamente, todos los campos se plantaban desde Octubre a Diciembre en esta región, y el 80% de ellos experimentaba de tres a cinco cortes antes de ser replantados. Tradicionalmente, la zafra se regía según el orden del número de corte realizado, empezando con la cosecha de la caña que se encontraba en su último corte, moviéndose progresivamente a cañas más jóvenes. Esto resultaba en que el mayor crecimiento se otorgaba a la planta y el menor crecimiento a posteriores cortes.

A medida que el área cultivada crece, la zafra se extiende enormemente. En la zafra 1990/1991, la

Figura 1: El gráfico de línea muestra las estimaciones realizadas utilizando el modelo de Digital Harvest (azul), las predicciones hechas por el cliente (verde) y el rendimiento real de la cosecha(amarillo). En todos los casos, las predicciones hechas por el modelo ha sido mayor al

temporada terminó a finales de Febrero mientras que en la zafra más reciente 2018/2019, la cosecha no terminó sino hasta principios de Junio. Este corrimiento en el cronograma resulta en un mayor tiempo de crecimiento dado al primer corte. Nuestro análisis muestra que la mayoría de las cosechas de primer corte en determinados suelos alcanzan su máximo potencial de rendimiento meses después de la cosecha. Este aumento en el tiempo de crecimiento impactaría positivamente el rendimiento si se le otorga al segundo corte. Por este motivo, un cronograma optimizado difiere significativamente del usado en la práctica convencional y resulta en un aumento en promedio del rendimiento posible del 2%, sin alterar limitaciones logísticas.

CONCLUSIONES:

- A) El **método biofísico** para estimar rendimiento de caña resulta altamente eficiente y supera con mucho a los métodos tradicionales.
- B) Las estimaciones de rendimiento a largo plazo requeridas para un modelo de rotación completa y una optimización del cronograma son sensibles a tendencias climáticas de largo plazo. Esto permite que el proceso de optimización proporcione resultados útiles y los mejores pronósticos disponibles de gran alcance .
- C) Para lograr los mejores resultados es necesario alimentar al sistema con la mayor cantidad de información verídica posible.
- D) En la medida que se utilice más este método, el nivel de precisión aumentará.

BIBLIOGRAFÍA:

Solorzano A. R. Martínez M. A. (2010) Memorias convención ATAM

Ricardo M. F. (2018). Modelación de la Caña en Latinoamérica. Comisión Europea

Chamo C. J. A. (2004). Tesis : Evaluación de 20 métodos de estimación de la producción de caña en pie de unidades experimentales de ensayos de caña de azúcar.

Rueda C. F. , Peñaranda M. L. A., Velásquez V. W. L., Díaz B. S. A. (2015). Aplicación de Metodología de análisis de datos obtenidos por percepción remota orientados a la estimación de caña, al cuantificar NDVI. CORPOICA Ciencia Tecnología Agropecuaria.

Araujo P. M. C. (2007). Estimativa da Produtividade agrícola da cana-de açúcar utilizando agregados de redes neurais artificiais: estudo de caso Usina Catanduva.

García, C., Montero, D., Soto, M. & Valencia, J. (2017). Estimación de productividad en caña de azúcar desde la percepción remota. Análisis Geográficos, 53, 35-49.