



UNIVERSIDAD DE MATANZAS
Facultad de Ciencias Técnicas

Programa de Doctorado en
Tecnologías y Procesos Industriales

MODELOS PREDICTIVOS PARA UN DIAGNÓSTICO ESPACIO-TEMPORAL DE PROCESOS DE SOPORTE Y PROVISIÓN AZUCARERA AGROINDUSTRIAL

TESIS PRESENTADA EN OPCIÓN AL GRADO CIENTÍFICO
DE DOCTOR EN CIENCIAS TÉCNICAS

Ing. Yasmany García López

Matanzas, 2023



UNIVERSIDAD DE MATANZAS
Facultad de Ciencias Técnicas

Programa de Doctorado en
Tecnologías y Procesos Industriales

MODELOS PREDICTIVOS PARA UN DIAGNÓSTICO ESPACIO-TEMPORAL DE PROCESOS DE SOPORTE Y PROVISIÓN AZUCARERA AGROINDUSTRIAL

TESIS PRESENTADA EN OPCIÓN AL GRADO CIENTÍFICO
DE DOCTOR EN CIENCIAS TÉCNICAS

Autor: Ing. Yasmany García López

Tutores: Dr. C. Juan Alfredo Cabrera Hernández
Dr. C. Lourdes Yamen González Sáez

Matanzas, 2023

PENSAMIENTO

“En prever está todo el arte de salvar”

José Martí,

Obras Completas, volumen 2.
Editorial de Ciencias Sociales,
La Habana, 1991

DEDICATORIA

A mi abuelo Juan Ramón López y mi tío Noel López, sus ejemplos de dedicación, perseverancia e intelecto, han sido motor impulsor para enfrentar grandes retos

AGRADECIMIENTOS

Mi más profundo agradecimiento a...

Mis padres Norma López y Mirtelio García por su apoyo en todo momento.

Mis tutores, Dr. C. Juan Alfredo Cabrera y Dr. C. Lourdes González, por su tiempo y dedicación al desarrollo de esta tesis.

Al Dr. C. Rafael Villegas por sus enseñanzas en el campo de la investigación

Al PhD. Stephen Wood, por su colaboración en mi aprendizaje de las herramientas estadísticas, que he aplicado en los trabajos científicos.

A PhD. Cheryl Palm y PhD. Pedro Sánchez, por ser artífices de los análisis a las bases de datos que hemos compilado en años de investigaciones.

Al MSc. Geovany Barroso, por el apoyo que permitió mi avance como investigador

A Ramón Blanco, por los innumerables intercambios y debates que propició entre los jóvenes que buscábamos saber un poco más de la química de suelo.

A Antonio Fernández, por su colaboración para llevar a vía de hechos, todas las recolectas de muestras de suelo que sustentan esta investigación y la visión de una agricultura de precisión en caña de azúcar.

A toda mi familia, por su preocupación y ocupación ante las diferentes dificultades.

A Solangel Riesgo por su apoyo en el inicio de mis investigaciones

A Yavay Sánchez, Alejandro Bermúdez, Grethel Sieiro, Miriam Orozco y Daily Hernández, porque la amistad también es sustento para los caminos largos.

Y a todos los que de una forma u otra han apoyado el desarrollo de esta tesis y mi formación como investigador. Muchas gracias

DECLARACIÓN DE AUTORIDAD Y NOTA LEGAL

Yo, Yasmany García López, declaro que soy el único autor de la siguiente tesis, titulada “Modelos predictivos para un diagnóstico espacio-temporal de procesos de soporte y provisión azucarera agroindustrial” y, en virtud de tal, cedo el derecho de copia de la misma a la Universidad de Matanzas, bajo la licencia *Creative Commons* de tipo *Reconocimiento No Comercial Sin Obra Derivada*, con lo cual se permite su copia y distribución por cualquier medio siempre que mantenga el reconocimiento de su autor, no haga uso comercial de la obra y no realice ninguna modificación de ella.

Matanzas, 10 de julio de 2023.

Yasmany García López

RESUMEN

Los procesos de soporte son la base para los servicios ecosistémicos. Este enfoque, paradigma del pensamiento ambiental actual, ha transitado de los ecosistemas naturales a los sistemas socio-ecológicos. En este caso, la agroindustria azucarera se caracteriza por la sucesión de etapas, desde los manejo del suelo en campos agrícolas hasta un procesamiento industrial de la caña de azúcar en diferentes días de zafra. Las extensiones de tierra y los días de zafra se caracterizan por la existencia de variabilidades espacio-temporales y su desconocimiento puede causar múltiples impactos. Por ello, se realiza un diagnóstico espacio-temporal mediante aprendizajes estadísticos, predicciones de tendencias y posibles escenarios, que aportan conocimientos sobre los procesos de soporte. Con el ajuste de modelos predictivos, se pronostica el comportamiento de una provisión azucarera agroindustrial hasta el año 2025; lo que es complementado con la utilización de una regresión lineal e identificación de predictores importantes. También se determinan sitios específicos a escala de sub-campo. Estos aspectos permitieron llegar a nuevas valoraciones biofísicas y económicas para comprender el impacto de los manejos en procesos de soporte; con un índice de perjuicio (I_{p-vp}) de 4,2 USD t^{-1} (499 CUP t^{-1}) de caña molida. Un valor correspondiente con un escenario espacio-temporal que combina la eficiencia en el manejo adaptado a la variabilidad de los nutrientes del suelo y el distanciamiento entre el potencial de provisión azucarera agroindustrial y la producción real. Los resultados obtenidos evidencian que las valoraciones biofísicas y económicas, así como los manejos, serán más precisos con la incorporación de la variabilidad espacio-temporal en procesos de soporte del sistema socio-ecológico azucarero.

Palabras clave: Servicios ecosistémicos; Tecnologías; Variabilidad; Predicciones,

ABSTRACT

Supporting processes are the foundation for ecosystem services. This approach is a paradigm to the present environmental thinking and has moved from natural ecosystems to socio-ecological systems. In this case, the sugar agroindustry is characterized by a succession of stages, from soil management in agricultural fields, to industrial processing of sugarcane on different harvest days. The extension of land and the days of the harvest are characterized by the existence of spatio-temporal variability and their not appreciation, can produce multiple impacts. For this reason, a spatio-temporal diagnosis is carried out, through statistical learning, trend predictions and possible scenarios, which provide knowledge about supporting processes. With the adjustments of predictive models, the performance of an agro-industrial sugar supply is forecast until the year 2025, which is complemented with the use of a linear regression and identification of important predictors. Specific sites are also determined at sub-field scale. These aspects allowed us to reach new biophysical and economic assessments to understand the impact of management on supporting processes; with a damage index (I_p-V_p) of 4.2 USD t^{-1} (499 CUP t^{-1}) for crushed sugarcane. A value corresponding to a spatio-temporal scenario that combines management efficiency adaptation to variability in soil nutrients and the gap between the potential of agro-industrial sugar provision and actual production. The results obtained show that the biophysical and economic assessments, as well as the management, will be more precise with the incorporation of the spatio-temporal variability in supporting processes of the sugar socio-ecological system.

Keywords: Ecosystem services; Technologies; Variability; Prediction

SÍMBOLOS Y ACRÓNIMOS

$KCl_{(s)}$: Fertilizante potásico (Cloruro de Potasio) con un 60% de $K_2O_{(s)}$

$K_2O_{(s)}$: Oxido de potasio, expresión del potasio asimilable del suelo e ingrediente activo del fertilizante potásico

MIEA: Millennium Ecosystem Assessment (Valoración de los ecosistemas del milenio)

$P_2O_{5(s)}$: Pentóxido de difósforo, expresión del fósforo asimilable del suelo e ingrediente activo del fertilizante fosfórico.

Resiliencia: Capacidad de los ecosistemas de volver a su estado natural, ante un perturbación.

SERFE: Servicio de Recomendación de Fertilizantes y Enmiendas

Sistema socio-ecológico: Ecosistema modificado por la actividad antrópica en la búsqueda de un beneficio económico y se debe basar en manejos de adaptación para lograr la sostenibilidad.

SPT: Fertilizante de superfosfato triple con un 46 % de $P_2O_{5(s)}$.

TEEB: *The Economics of Ecosystem and Biodiversity* (La Economía de los Ecosistemas y la Biodiversidad)

TABLA DE CONTENIDO

INTRODUCCIÓN.....	1
CAPÍTULO 1. FUNDAMENTOS TEÓRICOS.....	6
1.1 Enfoque de servicios ecosistémicos	6
1.2 Procesos de soporte y provisión del sistema socio-ecológico azucarero	10
1.2.1 Indicadores biofísicos de los procesos de soporte	12
1.3 Valoración de los procesos de soporte y servicios ecosistémicos	14
1.4 Modelos para predicciones espacio-temporales.....	19
1.4.1 Modelos causales y de series de tiempo.....	20
1.4.2 Modelos para análisis espaciales	22
1.5 Toma de decisiones y manejos adaptados para la sostenibilidad.....	23
1.5.1 Desafíos para la agroindustria azucarera	26
1.6 Conclusiones parciales del Capítulo 1.....	29
CAPÍTULO 2. MATERIALES Y MÉTODOS.....	30
2.1 Descripción del sistema socio-ecológico y diagnóstico espacio-temporal.....	30
2.1.1 Descripción general de la investigación	34
2.2 Recolección de datos.....	36
2.2.1 Recolección de muestras de suelo	36
2.2.2 Indicadores de disponibilidad de nutrientes del suelo.....	39
2.2.3 Indicadores de extracción azucarera	40

2.3	Análisis exploratorio.....	41
2.4	Analítica predictiva y modelo de series de tiempo.....	42
2.5	Analítica predictiva y modelos para análisis de causa-efecto	45
2.5.1	Selección de variables y modelos	46
2.5.2	Ajuste de modelos de regresión lineal y de polinomio.....	47
2.5.3	Diagnóstico de modelos de regresión	48
2.5.4	Validación de modelos de regresión	49
2.6	Analítica predictiva y modelos para análisis espacial.....	49
2.6.1	Ajuste de modelos para el análisis espacial.....	49
2.6.2	Validación cruzada.....	52
2.7	Valoración de perjuicios espacio-temporales del sistema socio-ecológico.....	53
2.7.1	Perjuicio y pérdidas en el proceso extracción azucarera	53
2.7.2	Perjuicio del manejo de fertilizantes por variabilidad a escala sub-campo.....	54
2.7.3	Índice de perjuicio de un escenario espacio-temporal	56
2.8	Conclusiones parciales del Capítulo 2.....	58
CAPÍTULO 3. RESULTADOS Y DISCUSIÓN		59
3.1	Resultado del análisis exploratorio	59
3.1.1	Descripción estadística de los datos colectados	62
3.2	Resultados de la analítica predictiva	64
3.2.1	Series de tiempo y variabilidad temporal de la provisión azucarera.....	64
3.2.2	Relaciones causales y variabilidad temporal de la provisión azucarera	67

3.2.3	Análisis de la variabilidad espacial de fósforo y potasio en el suelo.....	73
3.2.4	Variabilidad espacial a menor escala de análisis	77
3.3	Predicciones y valoraciones espacio-temporales	79
3.3.1	Pronóstico de provisión azucarera.....	79
3.3.2	Predicciones espaciales de la disponibilidad de nutrientes en el suelo	81
3.4	Perjuicios espacio-temporales de procesos de soporte y provisión azucarera.....	85
3.4.1	Costo de las pérdidas industriales. Un modelo de predicción	85
3.4.2	Costos por dosis de fertilizantes en excesos y déficit.....	88
3.4.3	Valoración de perjuicios espacio-temporal del sistema socio-ecológico	92
3.5	Conclusiones parciales del Capítulo 3.....	98
	Conclusiones generales	99
	Recomendaciones.....	100
	Referencias Bibliográficas.....	101
	Anexos.....	132

INTRODUCCIÓN

El término de procesos de soporte está comprendido dentro del enfoque de servicios ecosistémicos (SE); el cual se ha establecido como un marco de trabajo en el escenario internacional (Grunewald y Bastian, 2015). Este enfoque no se centra solo en los beneficios que tienen precios en los mercados, concebidos como servicios de provisión, también aborda aquellos que con frecuencia pasan desapercibidos en las valoraciones económicas tradicionales, pero que son fundamentales para la existencia de los servicios ecosistémicos y el bienestar humano. Los procesos de soporte son básicos para los sistemas socio-ecológicos. Según la Evaluación de los Ecosistemas del Milenio, estos procesos pueden ser de formación de suelo, ciclos de nutrientes y fotosíntesis (MIEA, 2005). La importancia de esta visión radica en que la transformación de los Ecosistemas en Agrosistemas genera múltiples conflictos espacio-temporales; con impactos a corto, mediano y largo plazo para los procesos de soporte y servicios ecosistémicos. La agroindustria azucarera es concebida en este trabajo como un sistema socio-ecológico, el cual genera un servicio de provisión azucarera que se afecta por múltiples causas, desde el campo agrícola, la transportación de la caña de azúcar y el procesamiento industrial. Sin embargo, establecer una relación directa con cada una de las causas no es una tarea sencilla; además, en la molienda de un día coinciden tallos de los disímiles campos agrícolas, con calidades variables.

El nivel de desarrollo del cultivo depende del estado del suelo (Adetunji y Osarenor, 2021) y es influido por impulsores de cambios antrópicos y naturales (Dominati *et al.*, 2014); pero la provisión azucarera agroindustrial, también se ve influenciada por la extracción de sacarosa del procesamiento industrial. Las condiciones de operación

permiten lograr un óptimo o no de rendimiento industrial (Kustiyo y Arkeman, 2019). Mayores o menores niveles de eficiencia en la agroindustria azucarera afectan de manera positiva o negativa a los servicios ecosistémicos y repercuten en los niveles de producción de los diferentes días de zafra. Entiéndase por eficiencia al acercamiento entre producción real y potencial azucarero del cultivo; así como la capacidad de adaptar los manejos a características específicas en los procesos de soporte (García *et al.*, 2022). Por ello, el desafío del sistema socio-ecológico azucarero está en lograr una mayor precisión de las valoraciones y en la implementación de manejos de adaptación, para la sostenibilidad. Aunque se han diseñado y aplicado diversas metodologías para el diagnóstico y valoración de los servicios ecosistémicos, ninguna forma de análisis, por sí sola, ha permitido captar en un único valor las sinergias y conflictos a diferentes escalas de los procesos y servicios ecosistémicos. Por ello, más que llegar a un valor de totalidad, sería más útil una forma de integrar los diferentes valores (Rincón-Ruíz *et al.*, 2014) y escalas espacio-temporales que se presentan en los sistemas socio-ecológicos. Sin embargo, la incorporación de múltiples indicadores convierte a la valoración de servicios ecosistémicos en un desafío (Smith *et al.*, 2011), aún más con las variabilidades espacio-temporales, las escalas de análisis y la incertidumbre (Hamel y Bryant, 2017). Diversos trabajos abordan la necesidad de realizar mediciones biofísicas (Lilburne *et al.*, 2020; Macintosh *et al.*, 2019), relacionarlas con valores económicos (Castillo-Eguskiza *et al.*, 2019) y en base a hechos emitir criterios que sustenten la toma de decisiones para influir de forma positiva en la sostenibilidad. Sin embargo, este enfoque de sistema socio-ecológico, de comprensión de los procesos de soporte y los servicios ecosistémicos, ha sido poco abordado en las valoraciones y toma de decisiones de la agroindustria azucarera. Para ello, en esta Tesis se utilizan diferentes indicadores biofísicos, relacionados con la química de suelo;

específicamente los elementos que son considerados en el manejo de fertilizantes para la caña de azúcar; donde, la identificación de sitios específicos es uno de los aspectos indispensables que permite mejorar la eficiencia en el manejo de recursos (Shannon *et al.*, 2019). Esto para una etapa inicial, que necesita de una agricultura de precisión; sin embargo, el servicio de provisión final de este sistema socio-ecológico, también requiere de eficiencia en la extracción azucarera. La pérdida industrial, por ejemplo, es un indicador relacionado al procesamiento de los tallos de caña que influye en la cantidad de azúcar recuperada y directamente afecta el beneficio económico. En ambos casos, la forma en que se obtiene y procesa el cultivo de la caña de azúcar es fuente de conflictos e impactos a diferentes escalas de análisis. El diagnóstico espacio-temporal de estos fenómenos requiere de grandes bases de datos que deben ser analizadas mediante formas efectivas, para aportar los elementos necesarios que pueden ser decisivos en la toma de decisiones y la sostenibilidad del sistema socio-ecológico azucarero.

Se plantea como **problema científico:**

¿Cómo realizar un diagnóstico de procesos de soporte y provisión azucarera agroindustrial en diferentes escalas espacio-temporales?

Para dar solución al problema científico planteado, se presenta la **Hipótesis:**

Si se utilizan modelos predictivos e indicadores biofísicos a diferentes escalas de análisis, se podrá ofrecer un diagnóstico espacio-temporal para procesos de soporte y provisión azucarera agroindustrial.

De esta forma el **Objetivo General** de la investigación es:

Proponer modelos predictivos e indicadores biofísicos para un diagnóstico espacio-temporal de procesos de soporte y provisión azucarera agroindustrial.

Los **Objetivos Específicos** son:

1. Fundamentar de forma teórica y práctica la utilización de modelos predictivos e indicadores biofísicos, para un diagnóstico espacio-temporal de procesos de soporte y provisión azucarera agroindustrial.
2. Seleccionar los indicadores biofísicos de procesos de soporte y provisión azucarera agroindustrial, así como las escalas de análisis que permitan una mayor precisión del diagnóstico espacio-temporal.
3. Predecir mediante modelos las tendencias espacio-temporales de los indicadores biofísicos seleccionados.
4. Valorar los estados y tendencias espacio-temporales, mediante los indicadores biofísicos seleccionados, para procesos de soporte y provisión azucarera agroindustrial.

Se destacan como los principales **Aportes y Novedad Científica** del trabajo:

Aportes

1. Modelos de regresión lineal y series de tiempo para valoraciones de la provisión azucarera agroindustrial.
2. Mapas de variabilidad espacial para elementos asimilables (fósforo y potasio) del suelo, confeccionados mediante modelos de *kriging* ordinario.
3. Relación entre cuantificaciones biofísicas y valoraciones económicas a diferentes escalas de análisis del sistema socio-ecológico azucarero.

Novedad

Predicciones espacio-temporales de procesos de soporte y provisión azucarera agroindustrial, mediante modelos e indicadores biofísicos, para mayor precisión en el diagnóstico del sistema socio-ecológico de la caña de azúcar.

Pertinencia y actualidad del tema

La tesis se encuentra en concordancia con los Objetivos de Desarrollo Sostenible (ODS):

9. “Industria, Innovación e Infraestructura”.

Meta: Que las industrias sean sostenibles, utilicen los recursos con mayor eficacia y promuevan la adopción de tecnologías y procesos industriales, ambientalmente racionales.

12. “Producción y Consumo Responsable”.

Meta: Lograr la gestión sostenible y el uso eficiente de los recursos naturales.

Meta: Lograr una gestión ecológicamente racional de los productos químicos, de conformidad con los marcos internacionales y reducir significativamente su liberación hacia la atmósfera, el agua o el suelo a fin de minimizar sus efectos adversos en la salud humana y el medio ambiente.

13. “Acción por el clima”

Meta: Promover mecanismos para aumentar la capacidad en la planificación y gestión eficaz, en relación con el cambio climático.

También, con el Plan Nacional de Desarrollo Económico y Social hasta 2030, instrumento rector de la política económica, social y ambiental del Estado cubano:

165. 1. “Garantizar un uso racional de los recursos naturales, la conservación de los ecosistemas y el cuidado del medio ambiente y el patrimonio de la nación”.

170. 3. “Proteger y utilizar de forma sostenible los bienes y servicios de los ecosistemas y el patrimonio natural y cultural del país”.

Además, las acciones sobre manejos eficientes de recursos naturales están en concordancia con el Decreto-ley No. 50 de 2021: “Sobre la conservación, mejoramiento y manejo sostenible de los suelos y el uso de los fertilizantes” y el Decreto No. 86 de 2023: “Del enfrentamiento al cambio climático”.

CAPÍTULO 1. FUNDAMENTOS TEÓRICOS

En los fundamentos teóricos se presenta un análisis crítico de la bibliografía, con el objetivo de sustentar el basamento científico y la importancia de esta visión de sistema socio-ecológico para la agroindustria azucarera. Se analiza la clasificación de los servicios ecosistémicos, su expresión en escalas espacio-temporales, su vinculación con sistemas de producción y los métodos de cuantificación, valoración, análisis de conflictos, los que se exponen como elementos indispensables para la sostenibilidad de la agroindustria azucarera.

1.1 Enfoque de servicios ecosistémicos

En el enfoque de los servicios ecosistémicos se considera como provisión a los productos obtenidos de los ecosistemas y agrosistemas: alimento, agua, madera y fibra; mientras que soporte son los procesos como la formación del suelo, fotosíntesis y ciclos de nutrientes que mantienen las condiciones para la vida en la Tierra (MIEA, 2005). Esta visión ha sido desarrollada en la literatura por diferentes autores (Adhikari y Hartemink, 2016; De Groot *et al.*, 2017; Waweru *et al.*, 2016). En Costanza *et al.* (1997), se exponen a los servicios ecosistémicos como flujos de materiales, energía e información del capital natural, los cuales combinados con la manufactura y servicios del capital humano producen bienestar a la sociedad. También, Burkhard y Maes (2017) los conciben como resultados de las interacciones entre las estructuras y procesos de los ecosistemas, en combinación con impulsores de cambio. Con el tiempo, diversas definiciones de los servicios ecosistémicos han evolucionado con un enfoque de base ecológica, pero todas enfatizan la importancia del vínculo entre ecosistemas y bienestar humano (De Groot *et al.*, 2017).

La Valoración de los Ecosistemas del Milenio mostró la importancia y el valor de los ecosistemas para la sociedad y las consecuencias de su degradación para la salud y el bienestar humano; además, estableció las bases científicas para reforzar la conservación y sostenibilidad de los ecosistemas (Eastwood *et al.*, 2016; Grima *et al.*, 2016; MIEA, 2005). Tres temas desarrollados por la Valoración de los Ecosistemas del Milenio son claves en el desarrollo de valoraciones integrales para la toma de decisiones: clasificación de servicios ecosistémicos, análisis de conflictos (*trade-offs*), así como la utilización de indicadores biofísicos y monetario (Rincón-Ruíz *et al.*, 2014). Esta noción se ha convertido en una piedra angular del pensamiento contemporáneo sostenible (Bull *et al.*, 2016). Su estudio, así como sus aplicaciones a la toma de decisiones, es un área creciente con amplias perspectivas para proveer soluciones viables a numerosos desafíos sociales y ambientales; como cambio climático, prevención de la desertificación y gestión del agua (Liquete *et al.*, 2016). La utilidad del enfoque de servicios ecosistémicos radica en la comprensión de estructuras, procesos y funciones de los ecosistemas (Fig. 1.1).

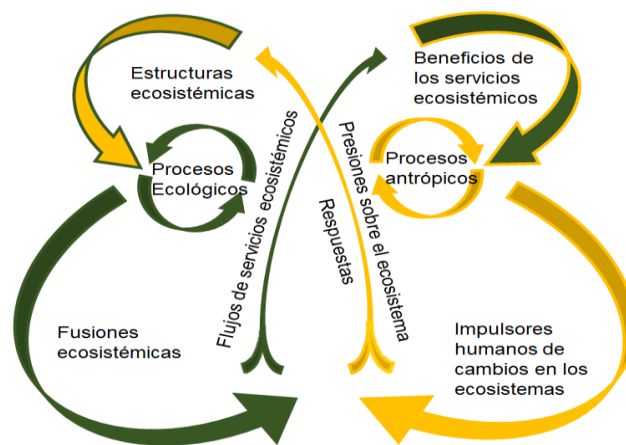


Figura 1.1 Diagrama conceptual para procesos y servicios ecosistémicos. Fuente: Elliott y O'Higgins (2020).

Los servicios ecosistémicos se presentan como una herramienta para hacer posible la realización de manejos sensibles a problemas ambientales (Muddiman, 2019) y son

comúnmente clasificados en tres clases principales: provisión, regulación y cultural, sobre la base de procesos de soporte (Dominati *et al.*, 2014) e incididos por impulsores de cambio. Las opiniones de especialistas son polémicas con respecto a una clasificación clara de procesos de soporte o servicios intermedios y finales (Bastian *et al.*, 2015). Según Potschin y Haines-Young (2017), el mayor acuerdo radica en la existencia de una senda, desde las estructuras y procesos biofísicos, hasta el bienestar humano (Fig. 1.2).

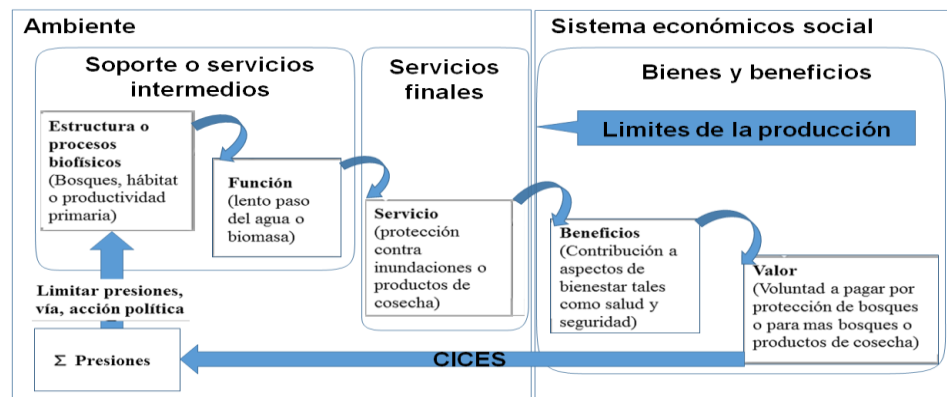


Figura 1.2 Modelo de cascada. Fuente: Potschin y Haines-Young (2017).

La clasificación de los servicios ecosistémicos según la economía de los ecosistemas y la biodiversidad (TEEB), considera a los servicios de soporte como estructura biofísica, procesos y funciones. Esta propuesta no logra un acuerdo entre instituciones académicas y científicas, especialmente debido al riesgo de pasar por alto el papel del suelo para los servicios (Ronchi, 2018). Para Fisher *et al.* (2011) los procesos de soporte son considerados como servicios intermedios, basados en complejas interacciones que contribuyen a los servicios finales; lo cual coincide con la Evaluación de Ecosistemas del Milenio del Reino Unido (Rincón-Ruíz *et al.*, 2014). Las discrepancias radican en las denominaciones de fenómenos que son base para la existencia del resto de los servicios ecosistémicos (Bastian *et al.*, 2015), sin duda un tema aún en debate, pero lo más importante a tener presente es que la mayoría de los procesos de soporte no tienen beneficios directos de consumo, sino

que funcionan como elementos de entrada para la obtención de otros bienes, por lo que su valor no debe agregarse a los valores de bienes producidos, para evitar una doble contabilidad (Elsasser y Englert, 2015). Se requiere, entonces, una separación clara entre estos y los servicios ecosistémicos finales (La Notte, D'Amato *et al.*, 2017); pero no requiere abstenerse de una consideración comprensiva de estructuras, procesos y relaciones de causa-efecto (Bastian *et al.*, 2015). Los estudios de los servicios ecosistémicos se han esforzado para entender los procesos de soporte, así como las diversas aplicaciones de los mismos (LaDeau *et al.*, 2017). En principio, los análisis se enfocaron en comprender las dinámicas de los ecosistemas, pero hacia la década del 1990, comenzaron a incluir la acción antrópica y su relación con los ecosistemas, bajo la denominación de sistemas socio-ecológicos (Schröter *et al.*, 2019), una forma que amplía el pensamiento sobre los ecosistemas para incluir a las personas. La investigación sobre la forma en que los sistemas socio-ecológicos trabajan y cuáles son los manejos para sostenerlos, precisa del enfoque de los servicios ecosistémicos (Potschin y Haines-Young, 2017). El concepto de *management* (manejo) debe proveer las formas de aprender y adaptar las acciones humanas para mantener las funciones básicas de un sistema socio-ecológico (Schröter *et al.*, 2019). La agroindustria azucarera puede ser comprendida como un sistema socio-ecológico, en donde se acciona sobre los procesos de soporte, mediante manejos y estructuras para potenciar la generación de productos requeridos por la sociedad. Además de la interacción humano-ecosistema, el desarrollo del enfoque de los servicios ecosistémicos trae consigo una serie de ideas: (1) la importancia de una visión holística para evaluar y manejar el ambiente; (2) el beneficio de valorar las causas y efectos de cambios en un ecosistema; y (3) el concepto de que el ambiente contiene un capital natural (Smith *et al.*, 2011).

1.2 Procesos de soporte y provisión del sistema socio-ecológico azucarero

Los procesos de soporte son un conjunto de operaciones que permiten la transformación de elementos de entrada en bienes o servicios ecosistémicos. Ambos (procesos y servicios), pueden ser modificados por impulsores de cambios naturales o antrópicos (Dominati *et al.*, 2014), así como por las interacciones entre los elementos bióticos y abióticos (Costanza *et al.*, 1997; MIEA, 2005, Riechers *et al.*, 2016). Una provisión agroindustrial depende de actividades antrópicas y del ecosistema, lo que constituye un sistema socio-ecológico interdependiente (Hori *et al.*, 2021) que requiere de investigaciones transdisciplinarias, para arribar a manejos sostenibles (Avriél-Avni y Dick, 2019).

La naturaleza socio-ecológica de la agroindustria azucarera puede ser presentada como una interrelación de procesos y estructuras que comienza con el adecuado manejo de recursos, para obtener una materia prima de calidad y se extiende hasta la extracción de sacarosa del cultivo (Fig. 1.3).



Figura 1.3 Dependencia de la provisión azucarera de los procesos de soporte.

El sistema socio-ecológico, persigue la obtención de azúcar; un servicio ecosistémico de provisión (García *et al.*, 2022), dependiente de las propiedades del suelo e influenciado por diferentes manejos (Adhikari y Hartemink, 2016; Pal, 2019). La aplicación de fertilizante, es uno de los manejos utilizados con frecuencia en la agricultura, para reponer los nutrientes, que son extraídos por sucesivas cosechas (Ahmad y Hussain, 2020); pero deben ser aplicados de forma racional para evitar impactos ambientales (Karagöz, 2021). En

otras palabras, los ciclos de nutrientes son esenciales para los servicios de provisión de base agrícolas y el mantenimiento de la fertilidad del suelo a largo plazo (Hoffmann *et al.*, 2019). Sin embargo, se necesita de contribuciones adicionales que emplean tecnologías y conocimientos (Schröter *et al.*, 2019); debido a que los nutrientes del suelo en las plantaciones con caña de azúcar son directamente afectados, en comparación con los ecosistemas naturales (El Chami *et al.*, 2020).

Otra característica del sistema socio-ecológico azucarero es la combinación de etapas agrícolas e industriales; esta última con diferentes operaciones que permiten extraer el azúcar contenido dentro del cultivo. La caña de azúcar pasa por un tándem de molinos, donde se ejercen presiones de compactación, se extrae el jugo de las fibras y se obtiene un producto diluido que es enviado al área de elaboración; en esa etapa se purifica y clarifica para obtener un jugo de mayor pureza. El jugo que sale del clarificador es pasado por estaciones de evaporación para concentrarlo gradualmente hasta obtener una meladura que alimenta a los tachos y alcanza concentraciones del 95 %, lo que da paso a la formación y crecimiento de los cristales de azúcar (Granja y Vidal, 2014). Cuando se considera que se ha alcanzado el punto máximo de agotamiento o crecimiento de los cristales, se pasa a centrifugar para la separación de los granos de azúcar de las mieles.

El azúcar húmedo es transportado a secadores para finalmente ser enviado al área de empaque, almacenamiento y distribución. La sucesión de operaciones mencionadas son denominadas en esta Tesis como extracción de sacarosa, un proceso de soporte con influencias sobre el servicio de provisión azucarera agroindustrial. Esta etapa industrial y su eficiencia permiten generar mayores o menores cantidades de provisión azucarera, donde factores como Pol en caña, pérdidas, aprovechamiento de la norma potencial o el tiempo perdido, repercuten en el comportamiento industrial (Ribas *et al.*, 2016). De

acuerdo con Gondkar *et al.* (2012), se pueden evaluar las actividades industriales bajo principios de ecología, similar a los ecosistemas naturales (Bruel *et al.*, 2018), donde se busca cuantificar ineficiencias en términos de flujos de recurso e impactos ambientales (Kendall y Spang, 2019).

1.2.1 Indicadores biofísicos de los procesos de soporte

Los procesos de soporte necesitan ser investigados en detalle, para arribar a decisiones y manejos adaptados que mejoren a los servicios ecosistémicos (Dominati *et al.*, 2014; Su *et al.*, 2018). Por ello, los indicadores biofísicos que los caractericen, son de utilidad en la adecuada planificación del territorio, así como en la integración de diferentes técnicas de valoración (Pandeya *et al.*, 2016); debido a que el incremento de un servicio de provisión también ocasiona cambios en componentes del ecosistema base, con impactos ambientales que frecuentemente solo son perceptibles a mediano y largo plazo (Inamuddin *et al.*, 2021). Los indicadores proporcionan una manera práctica de evaluar las propiedades de un sistema (Pomara y Lee, 2021). La cuantificación de un indicador biofísico es una medida de su estado, una cantidad a partir de observaciones, monitoreo y cuestionarios, que cubren un área de estudio de manera representativa, con valores en unidades físicas para los procesos y servicios ecosistémicos (Vihervaara *et al.*, 2017).

La agroindustria azucarera puede ser monitoreada desde diversos indicadores biofísicos (González-Corzo, 2015) correspondientes a las etapas agrícola e industrial. En la práctica, la mineralización de la materia orgánica, los ciclos de nutrientes, el secuestro de carbono, o el control de la erosión son procesos claves que existen como soporte en los ecosistemas agrícolas y naturales (Grunewald y Bastian, 2015) y se encuentran estrechamente vinculados a la provisión de SE (Ferraro *et al.*, 2010). Por ello, las salidas agrícolas como rendimientos de cultivo a diferentes escalas espacio-temporales, las determinaciones de

pH, los nutrientes asimilables o la materia orgánica del suelo, son indicadores biofísicos para las evaluaciones de los servicios ecosistémicos (González-Esquivel *et al.*, 2015). También los indicadores de eficiencia, pérdidas y aprovechamiento del potencial azucarero, durante una zafra azucarera, permiten la caracterización de los procesos que intervienen en la etapa industrial de obtención del azúcar (Quiala *et al.*, 2016).

En el desarrollo del cultivo de la caña de azúcar son necesario 16 elementos esenciales, pero, actualmente solo nitrógeno, fósforo y potasio se aplican regularmente como fertilizantes en Cuba (SERFE, 2014). Además, en el caso del nitrógeno solo se consideran el tipo de suelo, la cepa y el rendimiento, mientras que para el fósforo y el potasio se han determinado categorías que permiten realizar recomendaciones acorde a los estados del suelo (De León *et al.*, 2015). La importancia de estos últimos para la caña de azúcar radica en los aportes a su funcionamiento. El fósforo constituye un elemento esencial en la formación de ATP (Adenosín Trifosfato) y está unido a los procesos de intercambio de energía, por lo que sus niveles en el suelo se deben mantener o mejorar para el crecimiento del cultivo (Khan *et al.*, 2018). Los niveles de fósforo en el suelo también se reflejan en los jugos obtenidos en la etapa industrial (Fig. 1.4).

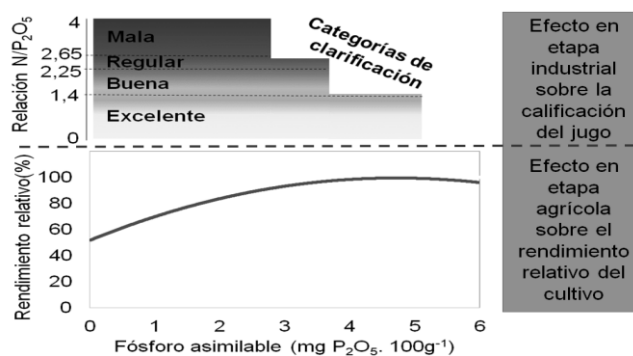


Figura 1.4 Efecto de los niveles de fósforo asimilable en la agroindustria.

Elaborado a partir: De León *et al.* (2015)

De acuerdo con De León *et al.* (2015), una cantidad adecuada de fósforo facilita la clarificación. Para un intervalo de pH en el jugo de 6,8 a 7,8 este elemento precipita como

fosfato de calcio y magnesio, lo que arrastra impurezas (Martínez *et al.*, 1987). El déficit de fósforo puede ocasionar disminución de la fertilidad del suelo por carencia a largo plazo; mientras que su exceso, constituye un gasto extra de recursos y puede ocasionar eutrofización de lagos y presas (Umar *et al.*, 2020). A la vez, el potasio contribuye con la activación enzimática y tiene un papel decisivo en la absorción de agua y conservación de la planta (De León *et al.*, 2015). Los excesos que pueden ser aplicados en la etapa agrícola y que son asimilados por el cultivo, incrementan el contenido de este elemento en los jugos del cultivo y en la etapa industrial aumentan las cantidades de cloruros y cenizas, lo que afecta la cristalización y recuperación de azúcar (Fig. 1.5) en la industria (De León *et al.*, 2015).




Figura 1.5 Efecto de los niveles de potasio asimilable en la agroindustria.

Elaborado a partir: De León *et al.* (2015)

Según Martínez *et al.* (1987), unos compuestos inorgánicos pueden ser favorables y otros perjudiciales en el proceso industrial y sus distribuciones cuantitativas en el jugo de la caña de azúcar son variables por diversos factores, entre ellos la fertilización.

1.3 Valoración de los procesos de soporte y servicios ecosistémicos

Los servicios ecosistémicos dependen de los procesos de soporte y se delimitan por las propiedades biofísicas y condiciones del área (Ronchi, 2018). Su valoración necesita de métodos que revelen las variabilidades naturales y los cambios en los ecosistemas, para

que la toma de decisiones logre una mejor adaptación a los impactos causados por la acción antrópica (Grunewald *et al.*, 2015). Las investigaciones, en este sentido, deben considerar los aspectos espacio-temporales (Adhikari y Hartemink, 2016), el establecimiento de las políticas que promuevan un manejo adecuado del suelo (Guzmán *et al.*, 2019) y la consideración de los numerosos vínculos existentes en los procesos y servicios ecosistémicos (Bünemann *et al.*, 2018), así como la consideración de análisis biofísicos y económicos en forma complementaria para una mejor comprensión de los servicios ecosistémicos (García *et al.*, 2022).

La inclusión de este enfoque en la toma de decisiones requiere de tecnologías robustas que incluyan el mapeo de su presencia (Vang *et al.*, 2016), el análisis de datos con el uso de la estadística, así como de modelos espaciales y temporales (Smith *et al.*, 2011). La sostenibilidad necesita que los flujos de servicios ecosistémicos sean igual o menor a las capacidades del ecosistema de proveerlos (La Notte, Maes *et al.*, 2017), lo que puede ser evaluado a través de la cuantificación e integración del conjunto de procesos que lo soportan (Grunewald *et al.*, 2015; Vihervaara *et al.*, 2017). Por ello, en diversos trabajos se abordan las valoraciones biofísicas como formas de estudio y comprensión de los SE (Castillo-Eguskitza *et al.*, 2019; Lilburne *et al.*, 2020; Macintosh *et al.*, 2019).

Aunque diversas metodologías han sido diseñadas para la valoración de servicios ecosistémicos con diferentes marcos disciplinarios, desde teorías del mercado, ciencias políticas, teoría de la resiliencia y ecología industrial termodinámica; hasta el momento ninguna ha permitido el reconocimiento de todos los valores y *trade-off*, que pueden ser insumo en la toma de decisiones de un territorio (Rincón-Ruíz *et al.*, 2014). El éxito de una medida fiable para los servicios ecosistémicos dependerá de las múltiples capas de análisis y de las estimaciones respecto al tiempo (Osorio-González *et al.*, 2020).

La cuantificación de SE con el empleo de métodos e indicadores biofísicos se ha utilizado para una variedad de propósitos: manejo del paisaje, contabilidad del capital natural, incremento de conocimientos y diseño de políticas (Vihervaara *et al.*, 2017). Los métodos incluyen mediciones, programas de monitoreo, mapeo de actividades, entrevistas a expertos y análisis estadísticos; donde las estructuras y procesos naturales, como los flujos de energía, materia y agua son esenciales en las valoraciones biofísicas (Grunewald *et al.*, 2015).

La cuantificación de procesos de soporte consiste en mediciones o estimaciones de aspectos relacionados al funcionamiento y a la estructura de los ecosistemas y pueden separarse en: 1) identificación de elementos estructurales de los ecosistemas y su asociación con la posibilidad de brindar un SE; 2) las que se enfocan en las estimaciones de flujos o procesos clave como soporte de SE; 3) las que identifican ineficiencias o deterioro en los procesos ecosistémicos mediante flujos de materiales y energía; 4) las de integración de procesos como condición básica para el análisis de *trade-offs* en la provisión de distintos SE (Ferraro *et al.*, 2010).

Para Smith *et al.* (2011), los estudios de los servicios ecosistémicos se han desarrollado en cuatro áreas fundamentales: (1) sistemas de información geográficas, (2) sensores remotos, (3) tendencias espaciales y (4) modelos jerárquicos. Los diversos estudios del tema han abordado las cuantificaciones, mediciones de procesos de soporte y servicios ecosistémicos, así como análisis de conflictos (Mokondoko *et al.*, 2018), junto al diagnóstico de distribuciones espaciales de diferentes indicadores, con el uso combinado de sistemas de información geográficas, geoestadística y estadística multivariada (Cai *et al.*, 2019; Hou *et al.*, 2017); además del análisis de relaciones mediante coeficientes de correlación entre indicadores continuos. También se destacan el desarrollo de métodos

más flexibles para analizar los vínculos entre múltiples servicios ecosistémicos (Cord *et al.*, 2019) y las estimaciones de elementos del suelo mediante modelos de predicción (Hosseini *et al.*, 2017).

Lo cierto es que existe un incremento del número de estudios que incorporan evaluaciones monetarias y no monetarias de procesos de soporte y servicios ecosistémicos, así como un desarrollo de diferentes métodos y análisis para la caracterización de estructuras, procesos y funciones (Burkhard y Müller, 2015; Kenter *et al.*, 2016). En diferentes trabajos se relacionan las propiedades del suelo (Adhikari y Hartemink, 2016; Dominati *et al.*, 2014) y las estrategias de manejos en los procesos de soporte de los servicios ecosistémicos (Macintosh *et al.*, 2019). También se caracteriza a la variabilidad espacial y su impacto en la productividad (Tola *et al.*, 2017), además de predicciones sobre múltiples servicios (MIEA, 2005). Para cuantificar diferentes componentes de SE, es necesario definir dos preguntas: ¿Qué se debe medir?, ¿cómo se debe medir?; además de la selección apropiada de métodos e indicadores (Vihervaara *et al.*, 2017).

La identificación de indicadores biofísicos, sus mediciones y valoraciones son herramientas para la comunicación de información en los sistemas socio-ecológicos, los cuales tienen que ser cuantificables, sensibles a diferentes usos de la tierra y a los cambios espacio-temporales (Grunewald *et al.*, 2015). Pueden utilizarse diferentes indicadores biofísicos para medir un solo proceso o servicio ecosistémico; su elección depende de varios factores, como propósito, hipótesis específica, escala espacial o temporal que se considere, así como la disponibilidad de datos (Cord *et al.*, 2019; Vihervaara *et al.*, 2017).

Las mediciones en procesos de soporte y de servicios ecosistémicos generan diversos valores, que con frecuencia requieren de una modelación que proporcione las predicciones para un mundo en constante cambio (Christin *et al.*, 2019). Sin embargo, se vuelve un

desafío diseñar los métodos para las colectas de indicadores biofísicos, así como el análisis de los múltiples parámetros y resultados de los modelos que son ajustados a estos valores (Smith *et al.*, 2011).

El uso de sensores proximales y remotos es otra vía que ha facilitado la estimación indirecta de diversos indicadores asociados a procesos de soporte y servicios ecosistémicos en diferentes escalas espaciales o temporales (Ferraro *et al.*, 2010). Este tipo de mediciones indirectas deben ser combinadas con modelos y otras fuentes de información ambiental, antes de ser utilizadas como cuantificaciones para las valoraciones biofísicas de los servicios ecosistémicos (Vihervaara *et al.*, 2017). Según Hou *et al.* (2017), en el análisis de distribuciones espaciales de diferentes propiedades químicas del suelo se hace necesario el establecimiento de métodos eficientes para la colecta de muestras (tabla 1.1).

Tabla 1.1 Diseños de muestreo de suelo en trabajos científicos publicados.

<i>Diseño de muestreo de suelo</i>	<i>Referencias</i>
En grilla regular	Bogunovic <i>et al.</i> (2014); Fu <i>et al.</i> (2010); Vasu <i>et al.</i> (2017)
En representación de tipos, usos y coberturas del suelo	Annabi <i>et al.</i> (2017); Bhunia <i>et al.</i> (2018); Rosemary <i>et al.</i> (2017); Wang y Shi (2018)
Acorde con la topografía	Wang <i>et al.</i> (2017)
Formadas por diferentes sub-muestras	Annabi <i>et al.</i> (2017); Bednářová <i>et al.</i> (2016); García y Orozco (2021)
En forma aleatoria	Xia <i>et al.</i> (2017)
En forma irregular	Bogunovic <i>et al.</i> (2017); Lin <i>et al.</i> (2014)
Aleatorio estratificado	Wang <i>et al.</i> (2017)

Para el autor de esta Tesis, lo importante de los diseños de muestreos de suelo no es la existencia de unos mejores que otro, sino la adaptación al sitio de estudio, el objetivo de trabajo y la viabilidad técnico-económica de realizarlo. Un muestreo en grillas regulares, con sucesivos puntos de muestreo, puede dar información del estado y tendencias de cambio del suelo a escalas sub-campo, pero implica mayores costos en recursos, tiempo y mano de obra, que un estudio de muestras compuesta, mientras que este último puede arribar a un valor representativo de un campo, sin embargo, posee mayor incertidumbre. Lo que contribuye con la viabilidad de los métodos y mediciones directas o indirectas, es el establecimiento de relaciones y uso de modelos estadísticos para realizar la predicción espacio-temporal de una variable objeto de estudio (Shannon *et al.*, 2019). En general, la utilización de indicadores biofísicos para el ajuste de modelos predictivos es un método de valoración que permite una comprensión de estados y tendencias al cambio, así como la visualización de escenarios futuros para los procesos de soporte. Ello favorece a eliminar, en gran parte, la incertidumbre, reaccionar con rapidez a condiciones variables de la agroindustria azucarera y a la elaboración de planes estratégicos de corto, mediano y largo plazo (Cabrera–Milanés y Rodríguez–Betancourt, 2015; Grunewald y Bastian, 2015).

1.4 Modelos para predicciones espacio-temporales

En los modelos estadísticos y geoestadísticos se establece la necesidad de crear colecciones de datos de campos colectados por métodos directos o indirectos (Bogunovic *et al.*, 2017), que permitan estudiar a los procesos de soporte y servicios ecosistémicos a diversas escalas, así como estimar los flujos de materia o energía (Willcock *et al.*, 2018). En un contexto agroindustrial azucarero, se pueden encontrar ejemplos de usos de modelos, como análisis de regresión lineal para evaluar relaciones con el rendimiento del cultivo (Rahman y Robson, 2016), modelo de polinomio para evaluar la reducción de rendimiento

en azúcar (Nashiruddin *et al.*, 2020); así como combinaciones de redes neuronales y algoritmos genéticos para predecir características del jugo de la caña de azúcar (Tarafdar *et al.*, 2020). También, modelos de *random forest*, *boosting* y máquinas de soporte vectorial para predecir el rendimiento agrícola (Hammer *et al.*, 2020; Natarajan *et al.*, 2016) y métodos *stepwise regression* para la selección de variables significativas (Kumar *et al.*, 2021). En Chiang *et al.* (2018), se obtienen modelos que mostraron consistencia en comparación con los resultados de los balances de masa. Ribas *et al.* (2016), mediante un análisis de componentes principales, expone con pesos significativos, las pérdidas industriales, el aprovechamiento del RPC y los tiempos perdidos (agrícola e industrial); igualmente Cabrera–Milanés y Rodríguez–Betancourt (2015) proponen modelos predictivos y destacan la importancia de las variables materia extraña y fresca de la caña, así como su relación con el Pol en jugo mezclado. En Shahzad *et al.* (2017) se correlaciona el recuperado azucarero con diferentes indicadores y rasgos morfológicos de la caña de azúcar. Estos trabajos destacan el análisis de indicadores del proceso industrial y el uso de la estadística, para, a partir de hechos, emitir criterios que contribuyan con el incremento de los beneficios del sistema.

1.4.1 Modelos causales y de series de tiempo

Los análisis predictivos persiguen obtener modelos que permitan predecir una variable objetivo para nuevas observaciones, en función de un conjunto de variables de entrada (Andrade y Flores, 2018). Lo cierto es que cada modelo tiene diferentes niveles de flexibilidad y restricciones, así como facilidad y dificultad para su interpretación (James *et al.*, 2021); las restricciones tienen que ver con el diagnóstico y cumplimiento del modelo con ciertos supuestos específicos. Dentro del diagnóstico del modelo para la regresión lineal se puede mencionar la significancia de los parámetros estimados, el análisis de

normalidad de los residuos, homogeneidad de varianza, puntos influyentes y la multi-colinealidad (Ramasubramanian y Singh, 2019).

Los modelos causales, en los cuales una variable respuesta es analizada en función de uno o más predictores, no son la única forma; también se puede analizar el tiempo como variable independiente y la regresión, entonces conforma un análisis de series de tiempo (Anderson *et al.*, 2012). El análisis de serie de tiempo es útil para obtener pronósticos de valores futuros y ayudar a tomar decisiones (Gil, 2016). A lo largo de los años, los análisis de series temporales se han llevado a cabo en diferentes ámbitos, mediante la metodología de Box y Jenkins (Alonso, 2021). También, se pueden destacar los aportes de la librería *forecast* para el lenguaje de programación (R), parte del sistema estadístico *fpp* (*Forecasting: Principles and Practice*) (Hyndman *et al.*, 2018), así como los trabajos de Rami Krispin, que en el año 2019 publicó *Hands-on Time Series Analysis with R*, acompañado de la librería *TSstudio* (Krispin, 2019).

Dada la incertidumbre generalizada sobre la capacidad de la agricultura para alimentar a una población creciente, el valor de los pronósticos de rendimientos puede ser utilizado como indicador en estudios de prospectiva sobre temas de seguridad alimentaria, así como de oferta y demanda (Delgadillo-Ruiz *et al.*, 2016). Las predicciones y pronósticos son útiles para las valoraciones biofísicas y económicas que se requieren en un enfoque de servicios ecosistémicos. De acuerdo con Zeki (2020), se necesita de un grupo adecuado de indicadores para monitorear y valorar cambios en los servicios ecosistémicos e identificar los perjuicios y beneficios ocultos de la forma en que se producen y procesan los alimentos que, según Müller y Sukhdev (2018), rara vez se reflejan en los análisis económicos convencionales.

1.4.2 Modelos para análisis espaciales

Un aspecto importante en la interpretación, análisis de datos y usos de modelos para un enfoque de servicios ecosistémicos son las elaboraciones de mapas y la identificación de variabilidad espacial. En la literatura científica se reportan estudios donde se ha analizado el comportamiento espacial de propiedades del suelo (Beguin *et al.*, 2017; Rosemary *et al.*, 2017; Wu *et al.*, 2019). Diferentes modelos de predicción permiten esto; por ejemplo: interpolación por el inverso del cuadrado de la distancia (IQD), interpolación por ponderación del inverso de la distancia (IDW) o interpolación geoestadística por *kriging*; por ello, el mapa resultante dependerá del método de interpolación definido y de los parámetros adoptados (Charlotte *et al.*, 2014).

En síntesis, se puede afirmar que, mediante el uso de la dependencia espacial que tienen los datos de muestras colectadas, en la geoestadística se emplea un algoritmo para predecir una variable investigada en lugares no muestreados (Fernández y Ribes, 2014). Los pasos básicos de la geoestadística como técnica son: análisis exploratorio de los datos, análisis estructural, predicción espacial y validación cruzada (García y Orozco, 2021).

La herramienta básica para el análisis de variabilidad espacial es el semivariograma y se emplea para cuantificar la correlación entre observaciones espacialmente distribuidas y para deducir los estimadores de las variables aleatorias en puntos no muestreados (Oliver y Webster, 2015); el semivariograma permite determinar la escala y magnitud espaciotemporal de la variabilidad que es mostrada en los mapas (Goovaerts, 2018). Mediante este, se construye la relación entre el vector de distancia y la semivarianza de valores experimentales y se ajusta un modelo teórico que permite determinar los parámetros que serán utilizados en la predicción espacial (Cai *et al.*, 2019; Kumar y Sinha, 2018).

Los modelos utilizados por diferentes autores han sido el exponencial, esférico y gaussiano (Guan *et al.*, 2017; Vasu *et al.*, 2017; Wang *et al.*, 2017). Estos modelos son utilizados posteriormente en la interpolación espacial de *kriging* ordinario (KO), el cual ha probado su utilidad y ventaja al compararse con diversos métodos, por su capacidad para proveer el mejor estimador no sesgado (Fernández y Ribes, 2014). El método de *kriging* aplicado al análisis espacial de propiedades del suelo; se observa en los trabajos científicos de Bogunovic *et al.* (2014) y Guan *et al.* (2017), donde se expone la variabilidad espacial de elementos, como el fósforo y potasio del suelo.

Debido a los elevados costos de los muestreos en campos y análisis de laboratorio, se dificultad incorporar el rigor geoestadístico con la viabilidad económica-operacional, para la caracterización de procesos relacionados con la fertilidad del suelo a escala comercial (Resende y Coelho, 2014). Diferentes autores se refieren a estas complejidades, donde se necesitan, al menos, 30 pares de datos para representar un punto confiable en el semivariograma; así como, un número de puntos en el espacio que no debería ser inferior a 50 (Gallardo, 2006; Oliver y Webster, 2015). Sin embargo, para analizar la existencia de anisotropía deben haber más de 500 puntos muestreados (Fernández y Ribes, 2014).

1.5 Toma de decisiones y manejos adaptados para la sostenibilidad

En concordancia con Liang *et al.* (2020), la valoración de los servicios ecosistémicos puede contribuir con la toma de decisiones, donde el uso de técnicas matemáticas y computacionales pueden aportar significativas mejoras a los sistemas de producción (Bocca *et al.*, 2015). Sin embargo, las valoraciones de procesos ecológicos y antrópicos, como soporte de una provisión azucarera agroindustrial, es compleja, pues existen diferentes formas de análisis en función de las cuales estará su valoración. La idea de captar un valor total es una ilusión, por diversas razones, entre las que se destacan: la existencia

de una senda desde las estructuras y proceso (Potschin y Haines-Young, 2017); los diferentes conflictos (Xiangzheng *et al.*, 2016); así como diversas formas de valoración (Burkhard y Maes, 2017; Grunewald y Bastian, 2015).

También, existen diferentes relaciones entre variables, de forma directa, indirecta, recíprocas y espurias (Thakkar, 2020). En este sentido, más que incluir un concepto de totalidad (valor total), sería más útil un concepto de “integrar” los diferentes tipos y lenguajes de valoración, para que se visualicen los diferentes impactos y conflictos (Rincón-Ruíz *et al.*, 2014). La toma de decisiones entonces, para un sistema como el agroindustrial azucarero, debe ser un proceso intencional que combine el análisis de información, uso de tecnologías, evaluación de alternativas y la decisión en sí misma (Müller y Sukhdev, 2018), para llegar a manejos adaptados a las características específicas de los procesos de soporte y mitiguen diversos impactos de las actividades antrópicas.

En la práctica, para alcanzar la eficiencia económica y el diseño de manejos adecuados, es necesario llegar a un punto donde se equilibre el valor extra de la producción industrializada, con el impacto extra generado. Así, el aprendizaje estadístico, el ajuste de modelos espaciales, causales y las series de tiempo, pueden ser utilizados para examinar cuáles factores individuales o combinados explican mejor las diversas circunstancias relacionadas con los sistemas socio-ecológicos y los manejos sostenibles de recursos (Bastian, 2015; Smith *et al.*, 2011).

En concordancia con Paterson *et al.* (2018), la habilidad para entender y valorar la agroindustria depende de las escalas en que se observan y modelan sus procesos; así como de la identificación de alternativas que potencian la producción y resuelvan también, los problemas que se crean (Ahumada-Tello *et al.*, 2019). Por ello, un seguimiento del estado y tendencia al cambio del suelo a través de indicadores biofísicos, deben influir en las

decisiones de manejo y las políticas a establecer (Gondkar *et al.*, 2012). Según Moebius-Clune *et al.* (2016), a través de la identificación de cuáles elementos deben restituirse, para mejorar la disponibilidad de nutrientes del suelo, se mitigará el efecto de elementos limitantes sobre el rendimiento agrícola. Los manejos adaptados a las características variables del suelo se vuelven una estrategia básica y en el caso de una agricultura de precisión, impulsan las aplicaciones variables de productos químicos (Shannon *et al.*, 2019); que refuerzan las propiedades del suelo y conservan su infraestructura ecológica (Jónsson *et al.*, 2019; Kibet *et al.*, 2016). La correcta combinación de fuente, lugar, momento y dosis de fertilizantes define la sostenibilidad y la salud del suelo (Bruulsema, 2018).

En este sentido, los estudios desarrollados por el Instituto de Investigaciones de la Caña de Azúcar han permitido concebir los algoritmos de fertilización para la restitución de los elementos fósforo y potasio. Las dosis óptimas de estos elementos se basan en lo requerido por el cultivo y las características del suelo; para maximizar los rendimientos agrícola y azucarero (Pérez *et al.*, 2015). Pero, aún persisten variabilidades dentro de los campos agrícolas y carencias de tecnologías para aplicaciones variables que dificultan la eficiencia de los manejos de fertilizantes por sitios específicos, en la agroindustria azucarera (García y Orozco, 2021).

La relación entre la caña que es molida y el azúcar que es producido es otra medida de eficiencia para este sistema socio-ecológico. Esa relación, en términos de porcentaje, es expresada como rendimiento industrial (RI) (Cala-Jústiz *et al.*, 2020) y requiere de diversas estrategias para su incremento, lo que ha constituido el objetivo de varias investigaciones, dentro de las cuales se pueden mencionar: la selección de variedades azucareras que produzcan la mayor cantidad de azúcar por unidad de área (Chiang *et al.*,

2018) y el estudio e implementación de métodos que permitan cuantificar con mayor precisión la influencia de variables tecnológicas (Ribas *et al.*, 2016). Además, se ha estudiado la relación entre indicadores industriales como materia extraña con los porcentajes de fibra en caña, bagazo y pérdidas en bagazo (Navarro y Rostgaard, 2014); la disminución de los tiempos de transportación entre los campos de cosecha de la caña de azúcar y su procesamiento en la industria (Rico *et al.*, 2013), así como la evaluación causa-efecto entre la calidad de la materia prima con el rendimiento industrial y producto final (Martínez y De León, 2012).

La sostenibilidad de la agroindustria azucarera, entonces, estará incidida por las condiciones relacionadas con estructuras, procesos y la capacidad de una toma de decisiones que influya en manejos eficientes de recursos, mejore la calidad de la materia prima, el procesamiento en la industria, así como el impacto ambiental. En otras palabras, las condiciones del suelo, sus manejos y condiciones climáticas, influirán en la materia prima principal de esta agroindustria, mientras que ineficiencias en el procesamiento de la caña reducirán la cantidad de azúcar que es producida (Kustiyo y Arkeman, 2019).

1.5.1 Desafíos para la agroindustria azucarera

La provisión azucarera (en términos de rendimiento agrícola o cantidad de azúcar) ha sido el principal objetivo de la agroindustria, con la transformación de ecosistemas en campos agrícolas. Sin embargo, al introducir al hombre y sus sistemas de producción, los equilibrios naturales se descompensan y dan como resultado severos cambios ambientales (Ramesh y Kaplanay, 2015). La actividad agroindustrial tiene impactos en los niveles de capital natural por la homogenización de la biodiversidad y el paisaje, lo que afecta suministros naturales y balance de nutrientes (Ganesapillai *et al.*, 2016; Keith *et al.*, 2016).

La modificación de la biodiversidad puede reducir la riqueza y el bienestar de una nación (Crespin y Simonetti, 2016).

De acuerdo con Perlatti *et al.* (2014), se necesita del uso eficiente de recursos, así como de sistemas de manejo adecuados para una producción y consumo sostenible. Por ello, la agroindustria azucarera debe afrontar como importantes desafíos a la producción de alimentos y la preservación del medio ambiente (González-Corzo, 2015). Sin embargo, los beneficios y perjuicios derivados del incremento en la provisión, por manejos directos en los procesos de soporte, pueden ser distribuidos irregularmente entre regiones; lo que constituye un problema relacionado con escalas espacio-temporales (Jax, 2019).

En un contexto agroindustrial azucarero se pueden ocasionar excesos y déficit de nutrientes, asociados a manejos de sitios específicos del suelo, en una etapa agrícola (García y Orozco, 2021), así como en un distanciamiento del potencial azucarero de la producción obtenida, en una etapa industrial (García *et al.*, 2022), lo que convierte en un importante desafío la mitigación de los impactos y conflictos espacio-temporales (Lauf *et al.*, 2019). Por ello, los estudios de indicadores biofísicos asociados a los procesos de soporte y servicios ecosistémicos son relevantes para determinar el efecto de las intervenciones, evaluar políticas y estimar escenarios futuros (Grunewald *et al.*, 2015).

Sin embargo, analizar los impactos simultáneos por favorecer un servicio y generar pérdidas en otros aspectos relacionados, no es una tarea simple (Villasante *et al.*, 2016).

Los impactos en un sistema socio-ecológico, precisan de la captación de los fenómenos complejos y variables, mediante la combinación de valores bajo diferentes magnitudes (Rincón-Ruíz *et al.*, 2014). Este es un tema que necesita de investigaciones para arribar a conclusiones sobre las condiciones ecológicas y económicas que causan impactos y conflictos, entre las producciones de base agrícolas y los servicios ecosistémicos (Power,

2010); además de cómo mediante manejos adaptados, estos se pueden reducir o eliminar (Loos *et al.*, 2019).

Lo cierto es que los indicadores biofísicos y económicos deben captar los impactos, que ocurren como consecuencia de los manejos adaptados o no a las variabilidades espacio-temporales en los procesos de soporte. Las variabilidades corresponden a cambios que pueden ser predichos, analizados y diferenciados en términos espacio-temporales para prever beneficios y perjuicios (Bastian y Grunewald, 2015). La falta de entendimiento de estas, dificulta la introducción adecuada de los servicios ecosistémicos en la toma de decisiones (Grunewald *et al.*, 2015).

La importancia de incorporar estos elementos a las valoraciones, toma de decisiones y manejos de los servicios ecosistémicos, reside en la existencia de sinergias y conflictos de tipo temporal o espacial, entre partes interesadas, en términos de reversibilidad; por la reducción de un servicio como consecuencia del aumento de otro (Xiangzheng *et al.*, 2016). Si no se consideran estos conflictos, se pueden generar graves distorsiones en los procesos de soporte, con problemas para la sostenibilidad (Schröter *et al.*, 2019; Zhen *et al.*, 2021). En otras palabras, sean negativos o positivos, los impactos afectan un desarrollo actual y futuro; además su expresión en valores biofísicos y monetarios contribuyen con argumentos factibles para los sistemas de producción (Macháč, *et al.*, 2021). Por ello, mediante valoraciones locales que provean entendimientos multifuncionales e identificaciones de impactos potenciales (Soy-Massoni *et al.*, 2016), se puede llegar a manejos adaptados para los servicios ecosistémicos (De Groot *et al.*, 2017; Grunewald y Bastian, 2015).

1.6 Conclusiones parciales del Capítulo 1

1. En el enfoque de servicios ecosistémicos se considera como procesos de soporte a la formación del suelo, la fotosíntesis y el ciclo de nutrientes; mientras que el término de provisión se relaciona con los beneficios como, alimento, agua, madera y fibras, obtenidos de los ecosistemas y sistemas socio-ecológicos.
2. En la agroindustria azucarera se acciona sobre los procesos de soporte mediante la creación de estructuras y la aplicación de manejos de recursos, para potenciar principalmente la generación de una provisión azucarera agroindustrial.
3. Una característica de la agroindustria azucarera, dentro del enfoque de servicios ecosistémicos, es que, además de los procesos de soporte relacionados con el suelo, están las operaciones para lograr una extracción de azúcar acumulada en el cultivo.
4. La cuantificación biofísica de procesos de soporte y provisión azucarera agroindustrial necesita de la identificación de indicadores que reflejen sus comportamientos, para la determinación de estados y tendencias al cambio.
5. Los conflictos e impactos relacionados a los manejos de los procesos de soporte son importantes para la toma de decisiones, pero sus identificaciones, cuantificaciones y valoraciones no son una tarea simple; lo que requiere del uso de bases de datos y aprendizajes estadísticos.

CAPÍTULO 2. MATERIALES Y MÉTODOS

En el Capítulo se abordan los diferentes elementos considerados para el diagnóstico de procesos de soporte y provisión azucarera agroindustrial. Se exponen los pasos seguidos en la identificación de los indicadores biofísicos, algoritmos y modelos; además de los criterios necesarios para realizar las predicciones espacio-temporales, así como, el procedimiento para la determinación de los índices de perjuicios, relacionados a las variabilidades espacio-temporales en los procesos seleccionados.

2.1 Descripción del sistema socio-ecológico y diagnóstico espacio-temporal

La elección del sistema socio-ecológico azucarero estuvo influenciada por los diferentes proyectos que dirige el Instituto de Investigaciones de la Caña de Azúcar (INICA) sobre la agricultura de precisión, en el cultivo de la caña de azúcar. El sistema socio-ecológico azucarero se ubica en el municipio Calimete, provincia de Matanzas, y se compone de un central para el procesamiento de la caña de azúcar, con el propósito de obtener diferentes productos requeridos por la sociedad.

El suministro de caña de azúcar (materia prima principal) es a partir de unidades productoras, las cuales se subdividen en bloques y estos, a su vez, en campos (unidad mínima de manejo). La concepción de unidades, bloques y campos (Fig. 2.1) es una estructura creada en el agrosistema de caña de azúcar, en la cual se establecen límites para el manejo de recursos, la gestión humana y se interrelaciona con las estructuras, procesos y funciones ecosistémicas en un espacio-tiempo determinado (García y Hernández, 2015). En este sistema la caña de azúcar es manejada en siete tipos de cepas, donde los mayores porcentajes son de retoños, socas y planta, mientras que un menor porcentaje corresponde a las cepas quedadas; las cepas responden a una denominación para las diferentes edades

y momentos de plantaciones del cultivo. Un tercio del área se encuentra con sistema de riego que permite alcanzar mayores rendimientos por unidad de área.

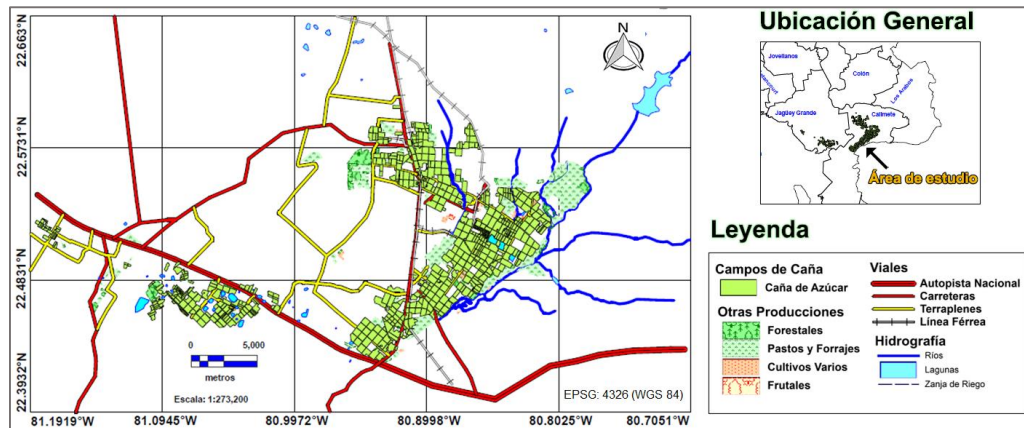


Figura 2.1 Mapa del sistema socio-ecológico azucarero objeto de estudio.

En el sistema socio-ecológico azucarero se observó un incremento de la producción a partir del año 2009. La recuperación estuvo en concordancia con el desarrollo de un proyecto para el uso de tecnología moderna y de agricultura de precisión, lo que favoreció con nuevos equipamientos y permitió, junto a un grupo de resultados científicos, incrementos notables en el rendimiento agrícola de 47 t ha⁻¹ en el año 2008 a 70 t ha⁻¹ en 2017 (García *et al.*, 2019).

Las complejidades del sistema socio-ecológico azucarero están comprendidas en diferentes escalas espaciales y temporales. Así, la generación de beneficios de una zafra no es un comportamiento homogéneo para cada uno de los días que la componen; como tampoco es un beneficio similar en todos los campos que generan el cultivo de la caña de azúcar, debido a diferentes sitios y necesidades específicas de elementos esenciales. Ambos sectores, agrícola e industrial, están sometidos a diversos impulsores de cambio, que fomentan beneficios o los perjudican y se relacionan con el manejo, la calidad de la caña de azúcar y la eficiencia industrial para procesarla.

Las dosis de fertilizantes recomendadas (aplicaciones químicas) pueden oscilar entre 25 y 80 kg ha⁻¹ de fósforo (P₂O_{5(s)}) y de 45 a 150 kg ha⁻¹ de potasio (K₂O_(s)) (SERFE, 2015). Los valores más altos, de las temperaturas medias, se registran en la temporada lluviosa y época de verano, con cifras alrededor de 27 °C, en los meses de julio y agosto. Las precipitaciones han estado comprendidas en un promedio anual de 1539 mm, donde el período lluvioso es de mayo a octubre, en el cual cae 85 % de las precipitaciones totales anuales; un período de pocas precipitaciones se establece en los meses de noviembre a abril, donde se registra 15 % de las lluvias anuales (García *et al.*, 2020).

El principal beneficio buscado tradicionalmente en el sistema socio-ecológico azucarero ha sido el servicio de provisión azucarera agroindustrial; para abastecer un consumo nacional y una exportación internacional. Sin embargo, llegar a este producto conlleva una sucesión de etapas, que pasan por componentes ecosistémicos y agroindustriales (Fig. 2.2).

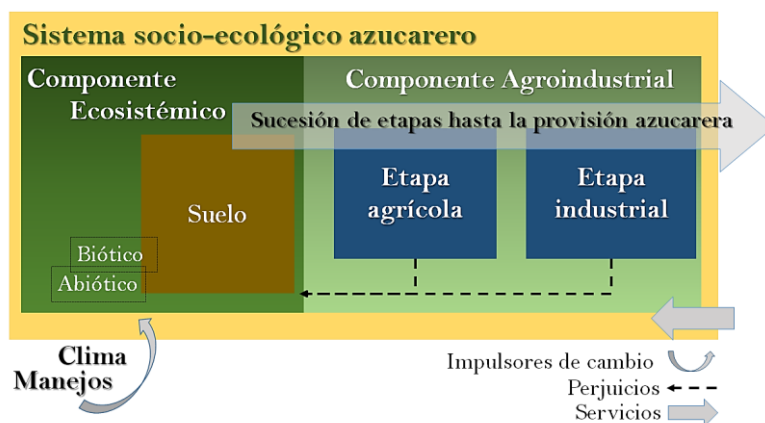


Figura 2.2 Modelo conceptual del enfoque de SE en la agroindustria azucarera

El componente ecosistémico corresponde a las estructuras y procesos naturales que son impactados por las actividades agroindustriales. Esta primera etapa es el ecosistema base para la actividad agrícola y que es modificado con la plantación del cultivo de la caña de azúcar. La producción de este cultivo se sustenta en el suelo, mediante interacciones

bióticas y abióticas, donde las acciones antrópicas permiten llegar a un máximo de rendimiento agrícola y azucarero. De este componente surgen los servicios ecosistémicos, sin embargo, el contexto agroindustrial es una extensión, desde una visión de sistema socio-ecológico; es decir, a las estructuras y procesos ecosistémicos se le adicionan las estructuras y procesos agroindustriales, en la búsqueda de un servicio de provisión.

En el componente agroindustrial se identifican dos etapas principales. En la primera, el cultivo de la caña de azúcar se genera bajo una estructura (arreglo del terreno en campos) y procesos agrícolas; en la segunda, la caña de azúcar cosechada pasa por un proceso industrial de extracción azucarera. En otras palabras, los servicios ecosistémicos de este sistema socio-ecológico son resultado de procesos de soporte naturales y agroindustriales. En la figura 2.2 se distinguen, además, aspectos como impulsores de cambio, perjuicios y servicios. Los impulsores de cambio son factores que promueven aumentos o decrecimientos de los flujos de servicios ecosistémicos y pueden ser de tipo climáticos o antrópicos; mientras los primeros son resultados de interacciones en las esferas del planeta, los segundos son manejos como, por ejemplo, las aplicaciones de fertilizantes para lograr mayores rendimientos agrícolas.

Para lograr la sostenibilidad, los manejos se deben basar en criterios de adaptación y mitigación de los perjuicios relacionados con los cambios del ecosistema. Los perjuicios son catalogados como impactos que necesitan ser internalizados dentro de las valoraciones económicas, para mejorar la cuantificación de los costos de producción y considerar a los procesos ecosistémicos.

Todo lo expuesto es distintivo del sistema socio-ecológico azucarero y se debe comprender que las ineficiencias en sus etapas, por separado o en conjunto, implican cambios en los servicios ecosistémicos. Por ello, la cuantificación y valoración de cómo

estos se proveen constituye un primer paso para su integración en la toma de decisiones (Fisher *et al.* 2011; Kamiyama, 2020). El diagnóstico del sistema socio-ecológico azucarero y sus servicios ecosistémicos, necesita de la comprensión de diferentes etapas con incidencias en los beneficios y perjuicios ocasionados; así como de una valoración de procesos, manejos y eficiencias.

Aunque toda acción antrópica implica un cambio, en mayor o menor medida, en los servicios ecosistémicos, la incidencia directa de los manejos sobre los procesos de soporte permiten el incremento del servicio de provisión azucarera agroindustrial y la existencia de perjuicios, que con frecuencia pasan desapercibidos en las valoraciones tradicionales de este sistema.

2.1.1 Descripción general de la investigación

Los pasos seguidos (Fig. 2.3) integran las acciones de recolecta de información, aplicaciones de algoritmos de aprendizaje estadístico y selección de modelos para las predicciones espacio-temporales, basadas en indicadores de procesos de soporte y provisión azucarera agroindustrial.

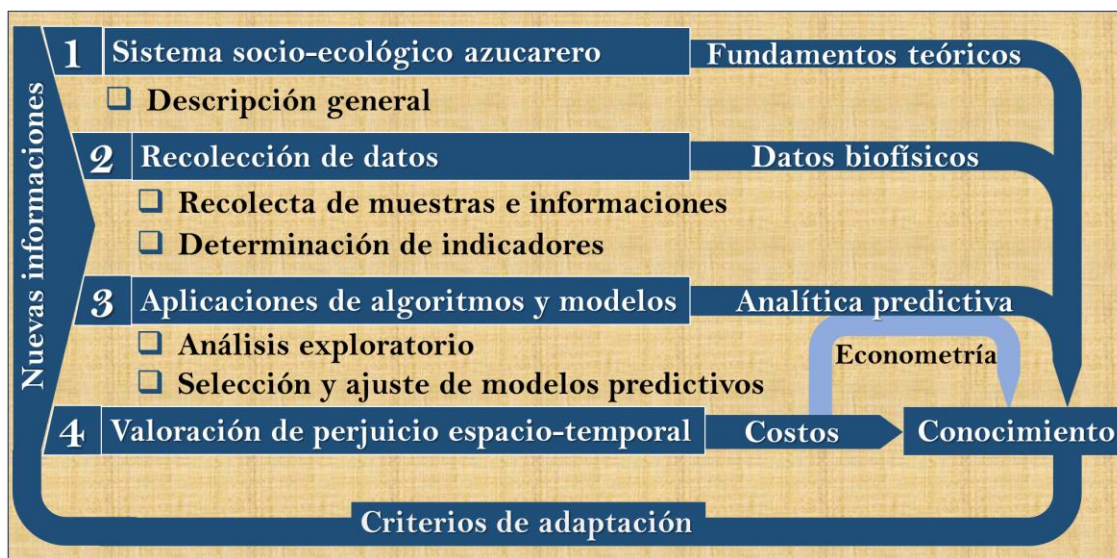


Figura 2.3 Esquema general para el diagnóstico espacio-temporal

En el diagnóstico espacio-temporal se emplean datos primarios y secundarios; los datos primarios se recopilan específicamente en investigaciones de campo y los secundarios se recolectan de las bases de datos existentes. Ambas fuentes de información, bajo la conceptualización de indicadores biofísicos, siguen el camino de toma de muestras, medición y análisis; útiles para determinar estados y prever tendencias, las cuales permiten estimar costos económicos que captan los perjuicios de ineficiencias en manejos adaptados a los procesos de soporte.

Acorde con el enfoque de servicios ecosistémicos, los procesos de soporte se clasifican en: formación de suelo, ciclos de nutrientes y la fotosíntesis (MIEA, 2005). Sin embargo, en un sistema socio-ecológico azucarero para obtener un producto final (azúcar) es necesario un procesamiento industrial; por ello, además de lo mencionado, la extracción de sacarosa es un proceso de soporte del sistema socio-ecológico azucarero.

Otra peculiaridad de los sistemas de base agrícola es la adición de fertilizantes en la dinámica de los ciclos de nutrientes naturales, lo cual modifica los estados de los elementos en el suelo. Para una diferenciación, se expone este proceso de soporte como disponibilidad de nutriente. Así, la tesis recoge la primera aplicación del enfoque de servicios ecosistémicos en la agroindustria azucarera evaluada y enfatiza la necesidad del diagnóstico de sus procesos de soporte.

¿Porque resaltar a los procesos de soporte? La respuesta a esa pregunta está en los manejos de adaptación. La transformación de los ecosistemas en sistemas que buscan una producción agrícola, demanda recursos naturales. El suelo es el soporte de los cultivos y su fertilidad se ve afectada sin una adecuada restitución de los nutrientes extraídos por sucesivas cosechas, lo que genera un evidente impacto ambiental. Además de esto, la provisión azucarera agroindustrial requiere de un procesamiento industrial.

Por ello, un diagnóstico para el sistema socio-ecológico azucarero conlleva la comprensión de lo que sucede a nivel espacial en los campos agrícolas y a nivel temporal en los diferentes días de zafra. Para afrontar el diagnóstico, se utiliza el sistema de información geográfica (SIG) con el *software* QGIS versión 2.6, así como la organización de bases de datos con *Microsoft Excel* 2013. Mientras que el lenguaje de programación de (R) *software*, versión 3.6.1 (R Core Team, 2019) permite el desarrollo de algoritmos de aprendizaje estadístico y ajuste de modelos predictivos. La analítica predictiva se relaciona con los métodos científicos para la recolección, organización, tabulación y permite el análisis de los datos, la predicción de comportamientos, además de la obtención de conclusiones válidas para la toma de decisiones. Mientras que la valoración de perjuicios se basa en captar las variabilidades espacio-temporales a menores escalas de análisis y exponer la utilidad de los modelos predictivos para determinar los impactos de prácticas ineficientes. De esta forma, se arriban a conocimientos oportunos para diversos criterios de adaptación, nuevos enfoques y teorías.

2.2 Recolección de datos

La primera etapa de trabajo se relaciona con la determinación de estados y para ello se identifican indicadores, se establecen las estrategias de recolecta de informaciones, además de la georreferenciación y cartografía de los datos que lo requieren.

2.2.1 Recolecta de muestras de suelo

La base de datos se confecciona mediante cuatro campañas de muestreo, para un total de 971 muestras de suelo; cada muestra es georreferenciada, requisito indispensable para los análisis espaciales. El muestreo realizado en el año 2015 es el primer análisis espacial realizado en este sistema socio-ecológico azucarero y evidencia la necesidad de estudiar la

variabilidad espacial de los elementos evaluados. Este estudio sirve de base al criterio de disminuir la escala de análisis en la segunda campaña de muestreo de suelo (año 2016); posteriormente, en 2019 se repitió el muestreo de suelo en las rejillas establecidas (año 2016), con el objetivo de comprobar la persistencia de la variabilidad espacial en el mismo polígono de estudio. Por último, bajo el mismo procedimiento de las 100 muestras de suelo, se realizó un estudio en un campo bajo sistema de irrigación.

La toma de muestras de suelo realizada en el año 2015 se localizó entre las coordenadas $22^{\circ} 26' 24''$ N a $22^{\circ} 33' 36''$ N y $80^{\circ} 49' 12''$ W a $81^{\circ} 3' 36''$ W sobre un suelo *Ferralsol* del municipio Calimete (Matanzas, Cuba). Cada muestra se formó en cada campo a partir de 30 sub-muestras tomadas a una profundidad entre 0 a 20 cm y en forma diagonal; posterior a la cosecha. En las áreas establecidas de una o más cosechas (93,3 % del área), las 30 sub-muestras se tomaron de forma alterna en las hileras de cultivo y entre estas. El muestreo se ajustó para áreas menores o iguales a 5 ha. En el caso en que las dimensiones de los campos excedían las 5 ha, se incrementó el número de muestras tomadas, mediante divisiones del área, hasta obtener las extensiones especificadas y aplicar el muestreo descrito (Fig. 2.4).




Figura 2.4 Esquema representativo del muestreo de suelo

Las divisiones fueron líneas trazadas para delimitar zonas de muestreos en los campos, mediante estacas guías, que no corresponden a límites permanentes. También se georreferencia el centro de cada zona de muestreos, para un total de 671 muestras de suelo colectadas en 4086,23 ha de la agroindustria azucarera. Este sistema está basado en

lo establecido por el SERFE para caña de azúcar, con la peculiaridad de no extender la representatividad de la muestra de suelo más allá de las cinco hectáreas (García y Orozco, 2021). Para evaluar el impacto asociado a posibles variabilidades espaciales dentro de las 5 ha, se realizó una segunda campaña de muestreo de suelo.

Este estudio se ejecutó en áreas agrícolas de la Unidad de Producción de Caña de Azúcar “Dagoberto Rojas”, ubicada entre las coordenadas $22^{\circ} 26' 28''$ N a $22^{\circ} 26' 41''$ N y $80^{\circ} 56' 25''$ W a $80^{\circ} 56' 40''$ W (Fig. 2.5). Las muestras de suelo se tomaron a la profundidad de 0 a 20 cm en 5,6 hectáreas plantadas con caña de azúcar. En el momento de muestreo, el campo se encontraba en su ciclo de retoño y sin riego. Las muestras fueron tomadas en cuadrículas y los puntos de muestreo se distribuyeron con una separación de 50 m a lo largo de los surcos hasta llegar a 500 m y 10 m entre surcos hasta llegar a 100 m. En el estudio se colectaron 100 muestras de suelo, que fueron utilizadas en las valoraciones geoestadísticas realizadas posteriormente. Esto coincide con los criterios de diversos autores de no coleccionar un número de muestras inferior a 100 (Gallardo, 2006; Oliver y Webster, 2015).

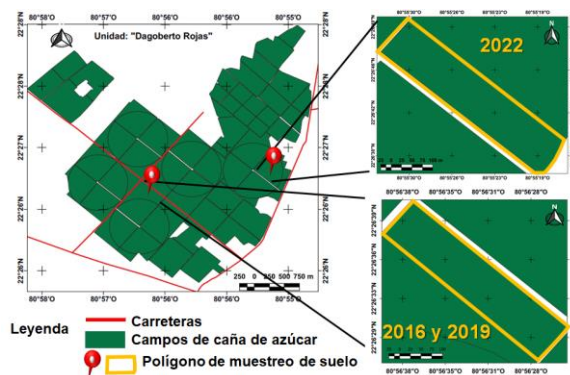


Figura 2.5 Mapa de los polígonos de estudio de variabilidad espacial del suelo

En este polígono se repitió el estudio en el año 2019, mientras que para 2022, con el mismo procedimiento, se muestreo un campo bajo condiciones de irrigación. Las recolectas de muestras se insertaron en las etapas de trabajo de los proyectos: “Tecnologías de

agricultura moderna para caña de azúcar en la UEB Jesús Rabí” y “Tecnología para adecuar el manejo de suelo y cultivo a la variabilidad del sistema agroindustrial azucarero”, ambos conducido por el INICA. Así como en el proyecto: “Valoración económica de los BSE, en función de lograr beneficios ambientales y económicos, en sitios seleccionados”, conducido por el Centro de Servicios Ambientales de Matanzas (CSAM).

2.2.2 Indicadores de disponibilidad de nutrientes del suelo

Los indicadores seleccionados para el diagnóstico de variabilidades espaciales en procesos de soporte de la etapa agrícola y su interacción con el componente ecosistémico, fueron aquellos que identifican un estado del suelo. En este caso, los relacionados con el manejo de nutrientes para la caña de azúcar en Cuba, pues los fertilizantes fosfóricos y potásicos son aplicados en función de la cantidad de estos elementos asimilables en el suelo, según la relación estado-categoría-dosis requerida (SERFE, 2014).

Los análisis químicos se realizaron en el Laboratorio de Suelo, Agua y Tejido Vegetal del Instituto de Investigaciones de la Caña de Azúcar, Matanzas. Las determinaciones del laboratorio permiten identificar los estados de los nutrientes del suelo; según lo requerido por el SERFE estos son: fósforo asimilable ($\text{mg } 100 \text{ g}^{-1}$) y potasio asimilable ($\text{mg } 100 \text{ g}^{-1}$), extraídos con $\text{H}_2\text{SO}_4(\text{ac})$ 0,1 N, un método conocido como “Oniani” (Pérez *et al.*, 2015); también, la determinación de pH en Cloruro de potasio para muestras de suelo (SERFE, 2014).

La utilidad de los resultados numéricos de los análisis de suelo depende de tenerlos relacionados con la cantidad de nutrientes que se necesita aplicar, para obtener rendimientos óptimos (Pérez *et al.*, 2015). El establecimiento de categorías separa los suelos de alta probabilidad de respuesta a la fertilización, de aquellos con poca probabilidad (Sánchez, 1981). El SERFE trabaja con categorías para los elementos

asimilables de suelo (Anexo 1) y el caso del potasio, además de las cantidades identificadas en el suelo, se especifica el rendimiento del cultivo (Pérez *et al.*, 2015).

2.2.3 Indicadores de extracción azucarera

El diagnóstico de variabilidades temporales en la etapa industrial se ve favorecido por la existencia de informaciones disponibles en bases de datos a diferentes escalas de análisis (diario, mensual, trimestral y anual). A partir de estas, se confeccionan tres bases de datos para los indicadores industriales y mediante las mismas se ajustan diferentes modelos, según la escala de análisis del periodo de tiempo 2004 al 2021. Se considera una escala de valores diarios para adquirir suficiente información, que permita el análisis de relaciones causa-efecto.

Se seleccionan tres zafras de forma aleatoria en el período mencionado, con un total de 340 días que abarcan la extracción azucarera en los años 2014, 2015 y 2020. La elección de una escala diaria en diferentes años responde a la necesidad de mayor cantidad de datos; pues en una sola zafra, no se dispone de información suficiente para realizar los análisis causales con múltiples predictores y elementos estadísticos de ajuste y validación, donde se deben seleccionar entre 10 y 20 valores por cada variable (McDonald, 2014), además de dividir los datos en entrenamiento y prueba.

Los datos disponibles en los registros fueron: Rendimiento Potencial en Caña (RPC), Aprovechamiento Rendimiento Potencial en Caña (A_RPC), Aprovechamiento de la Norma Potencial (ANP), Materia extraña (M_Ext), Pureza de Miel Final (P_MIEL_FINAL), Recobrado (RECB) y las pérdidas en bagazo, miel, cachaza e indeterminadas, que son combinadas en un índice de Pérdidas Totales (PERD_T). Los indicadores que serán utilizados para predecir el comportamiento de la provisión azucarera agroindustrial, bajo la nomenclatura estadística son predictores; es decir, los indicadores

son herramientas para medir el comportamiento de propiedades del sistema socio-ecológico azucarero, a la vez, son predictores cuando se utilizan como variables independientes, en el ajuste de modelos que pretenden predecir las tendencias de una variable dependiente.

Una visión aportada en esta Tesis es la consideración del beneficio recibido en base a la materia prima y su procesamiento; es decir, la cantidad de beneficio en función de las toneladas de caña de azúcar molida, en este caso, la relación de kilogramos de azúcar por tonelada de caña de azúcar molida (kg t^{-1}). Al considerar este último como indicador de provisión azucarera agroindustrial, el análisis no se centra en el volumen de producción, sino en la eficiencia para obtener la provisión de azúcar como beneficio final comercializable, lo que sirve para evaluar el proceso de soporte de extracción azucarera.

2.3 Análisis exploratorio

En los análisis estadísticos, además del lenguaje de programación (R), se utilizan diferentes librerías (Anexo 2), que permiten la realización de los análisis exploratorios, el uso de histogramas de frecuencias, la construcción de gráficos de dispersión y la identificación de valores extremos que dificultan la construcción de modelos válidos (Kumar y Sinha, 2018). Según Cahn *et al.* (1994) y Wani *et al.* (2013), los valores extremos se pueden detectar a partir de valores en el umbral de cuatro veces la desviación estándar alrededor de la media.

En esta investigación fueron excluidos los valores mayores a $19 \text{ mg } 100\text{g}^{-1}$ para el caso del fósforo asimilable, pues se alejan de la media y se presentan como valores aislados; por lo que se trabajó la interpolación con 668 valores para este elemento. Para el potasio asimilable se excluyeron los valores mayores a $33 \text{ mg } 100\text{g}^{-1}$, por los criterios ya mencionados; la interpolación para este último se realizó con 664 observaciones.

Otro aspecto importante es el acercamiento de los datos a una distribución normal. Acorde con diversas referencias científicas, entre los principales elementos para analizar la normalidad de los datos, se encuentran: los coeficientes de asimetría y curtosis, el histograma de frecuencias, el gráfico cuantil-cuantil (Q-Q), así como la prueba de normalidad (Bhunja *et al.*, 2018; Fu *et al.*, 2010; Vasu *et al.*, 2017; Wang *et al.*, 2017). Según Bogunovic *et al.* (2014), el alejamiento de los datos de una distribución normal tiene importantes implicaciones en el desarrollo de los métodos de interpolación espacial. Para lograr un mejor acercamiento a esta distribución, en las variables que lo requirieron, se utiliza la transformación logarítmica (2.1):

$$\text{Variable transformada} = \log_{10}(\text{variable medida} + X) \quad (2.1)$$

Donde:

X: es un escalar sumado a cada valor. Para determinar el mismo se realizaron sucesivas corridas y se encontró que con 0,5 se tiene un buen ajuste a una distribución normal, en las diferentes determinaciones realizadas a las muestras de suelo, excepto para fósforo asimilable, donde el factor obtenido para el muestreo de suelo del año 2016 fue de 0,4. La elección de la transformación corresponde a la de mejor ajuste a una distribución normal. Si los datos no pueden ser modelados con una distribución normal, deben estar, al menos, lo más cerca posible (Zhang, 2006).

2.4 Analítica predictiva y modelo de series de tiempo

El análisis de series de tiempo es la forma de comprender la estructura y extraer comportamientos significativos de una serie de datos para ser utilizado en el pronóstico de eventos futuros (Krispin, 2019). Las series de tiempo se pueden definir como un caso particular de los procesos estocásticos, pues son una secuencia de valores aleatorios,

equidistantes cronológicamente, con periodicidad variables (anual, semestral, trimestral, mensual, o diaria), según la frecuencia en la que los datos son recolectados.

Para este estudio, los datos de provisión azucarera utilizados fueron consolidados por trimestres, para el período de enero 2004 hasta mayo 2021. La metodología para realizar pronóstico es la de Box – Jenkins, una de las más utilizadas para estos fines (Hassan *et al.*, 2019; Mwangi *et al.*, 2017; Sanjeev *et al.*, 2015), donde se llega a un modelo autorregresivo (AR) integrado de medias móviles (MA) conocido como ARIMA [(p; d; q) (P; D; Q)_s]. Los puntos clave de la metodología de Box-Jenkins, de acuerdo con Ramasubramanian y Singh (2019), se resumen en:

- a) Verificar si la serie es estacionaria; si no lo es, diferenciarla hasta alcanzarla
- b) Identificar un modelo tentativo
- c) Estimar el modelo.
- d) Verificar el diagnóstico (si este no es adecuado, volver al paso b).
- e) Usar el modelo para pronosticar.

A la hora de elaborar el modelo ARIMA para una serie temporal, se considera si existe una variabilidad estacional, lo que implica que la observación de un mes y el mismo mes del año anterior tienen una pauta de comportamiento similar y estarán temporalmente correlacionadas. Por lo tanto, el modelo ARIMA, apropiado para este tipo de series, deberá recoger las dos clases de dependencia inter-temporal.

En la identificación se trata de proponer los modelos $ARIMA(p, d, q) (P, D, Q)_s$ que puedan representar la dinámica de la serie de tiempo. En primer lugar, se analiza el carácter estacionario; una serie estacionaria es aquella que mantiene una media y varianza constante. Para el modelo se seleccionan los órdenes (p, q) que responden a la estructura regular estacionaria; mientras que $(P, Q)_s$ corresponden a la estructura estacional

estacionaria, donde (P, p) son el orden del polinomio autorregresivo estacionario; (Q, q) el orden del polinomio de medias móviles; (D, d) corresponde con la derivación necesaria para hacer a la serie estacionaria y (s) es el elemento relacionado a la variabilidad estacional, que en el caso trimestral es igual a 4 (Krispin, 2019). El carácter estacionario de la serie se comprueba mediante el correlograma graficado y la prueba estadística de Dickey-Fuller; donde se establece:

1. Planteamiento de Hipótesis
2. Significancia $p\text{-value} < 0,05$

H_0 : La serie es no estacionaria

H_1 : La serie es estacionaria

La selección y estimación de los órdenes $(p; q)$ y $(P; Q)$ para que el modelo se ajuste a la serie estacionaria, se realiza mediante el estudio de la función de autocorrelación simple (ACF). También, con el uso de la función “*auto.arima*” de la librería *forecasting* de Hyndman *et al.* (2018), se comparan diferentes modelos y se selecciona el mejor ajuste para la serie de tiempo.

En la validación se trata de comprobar que el modelo propuesto se ajusta bien a los datos y reproduce la estructura de comportamiento de la serie. Para ello, se consideró el análisis de los residuos del modelo, donde se analiza el acercamiento a una distribución normal, mediante los gráficos de histograma, así como la prueba de *Lilliefort*.

Se consideraron las pruebas de *Box-Pierce* y *Ljung-Box* y el análisis de error del modelo se basó en la variación existente entre el valor real de la variable y su valor pronosticado (2.2), así como la medición de bondad ajuste de la serie para el modelo en particular, con los criterios Akaike (AIC), su forma corregida (AICc); junto al criterio Bayesiano (BIC), acorde con Krispin (2019).

$$e_t = Y_t - F_t \quad (2.2)$$

Donde:

e_t = error del pronóstico en el periodo t.

Y_t = valor real de la variable en el periodo t.

F_t = valor pronosticado de la variable en el periodo t.

Como existen observaciones y pronósticos para (n) períodos, entonces se calcula (n) errores, con los cuales es posible determinar el conjunto de mediciones estadísticas que sirven para comparar entre modelos (2.3 a 2.7); estas son: Error medio (*mean error*, o ME); Raíz cuadrada del error medio (*root mean square error*, o RMSE); Error absoluto medio (*mean absolute error*, o MAE); Error porcentual medio (*mean percentage error*, o MPE) y Error porcentual absoluto medio (*mean absolute percentage error*, o MAPE) (Krispin, 2019).

$$ME = \frac{\sum(Y_t - F_t)}{n} \quad (2.3) \quad MPE = \frac{1}{n} \sum_{t=1}^n \left(\frac{Y_t - F_t}{Y_t} \right) \quad (2.6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2} \quad (2.4) \quad MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - F_t}{Y_t} \right| \quad (2.7)$$

$$MAE = \frac{\sum |Y_t - F_t|}{n} \quad (2.5)$$

2.5 Analítica predictiva y modelos para análisis de causa-efecto

Los métodos causales asumen que el factor a ser predicho exhibe una relación causa-efecto con uno o más predictores (Contreras-Juárez *et al.*, 2016). Existe una gama de algoritmos de aprendizaje para analizar relaciones entre indicadores; con diferentes niveles de flexibilidad y entendimiento. En este caso se utilizó la regresión lineal, por su fácil comprensión, aunque se tiene que cumplir con diferentes condiciones. El modelo de regresión lineal múltiple es la extensión del modelo de regresión simple a P variables explicativas; matemáticamente la relación lineal se puede escribir por (2.8):

$$Y = B_0 + B_1x_1 + B_2x_2 + \dots B_px_p + e \quad (2.8)$$

Donde,

- Y es la variable respuesta;
- X_1, X_2, X_p , son las variables explicativas, predictores o variables independientes
- B_0, B_1, B_2, B_p , son los coeficientes de regresión
- e se suponen errores aleatorios con distribución normal, media cero y varianza σ^2

Para analizar la relación entre los predictores y la variable respuesta, se realiza una prueba de hipótesis. La hipótesis es contrastada y se comprueba el valor de la probabilidad (*p-value*); si el *p-value* $> \alpha$ (α es igual a 0,05), no se rechaza la hipótesis nula H_0 . Sin embargo, si *p-value* $< \alpha$, se rechaza la hipótesis nula de que la pendiente es igual a cero (Carrasquilla-Batista *et al.*, 2016; James *et al.*, 2021).

2.5.1 Selección de variables y modelos

Cuando se quiere elegir el mejor de entre un conjunto de modelos, es necesaria una medida que permita compararlos. Las medidas de bondad de ajuste fueron la Suma de los Residuos al cuadrado (RSS) y el coeficiente de determinación (R^2); también se consideró el criterio Mallows (C_p) y el R^2 ajustado. El método de mejor modelo de selección sufre limitaciones computacionales, para cantidades de predictores mayores a 40 (James *et al.*, 2021), por lo que en este caso puede ser utilizado sin dificultad.

El esquema general de la selección consistió en:

1. Crear un conjunto de modelos, todos los posibles (*best subset*), mediante diferentes combinaciones de los predictores disponibles.
2. Para cada posible tamaño de modelo (1 predictor, 2 predictores...) se selecciona el mejor basándose en el RSS de los datos de entrenamiento.

3. Los modelos finalistas de cada tamaño se comparan entre ellos para identificar el mejor basado en la estimación de diferentes criterios de error (C_p , R^2 ajustado).

2.5.2 Ajuste de modelos de regresión lineal y de polinomio

Entre las mediciones más comunes para el ajuste del modelo se encuentra el R^2 y el RSE (James *et al.*, 2021). El error estándar de los residuos (RSE) mide la desviación promedio de cualquier punto estimado por el modelo, respecto de la verdadera recta de regresión poblacional (2.9).

$$RSE = \sqrt{\frac{1}{n-p-1} RSS} \quad (2.9)$$

Grados de libertad (Gl) = número observaciones - número predictores - 1

Coefficiente de determinación R^2 (2.10): describe la proporción de variabilidad observada en la variable dependiente Y explicada por el modelo, respecto a la variabilidad total. Su valor está acotado entre 0 y 1. Al ser adimensional, presenta la ventaja frente al RSE de ser más fácil de interpretar.

$$R^2 = \frac{SCT - SCR}{SCT} \quad (2.10)$$

Donde:

SCT es la suma de cuadrados totales y SCR es la suma de cuadrados residuales.

Se pueden realizar extensiones del modelo lineal. La manera estándar de extender la regresión lineal en donde la relación entre los predictores y la variable respuesta es no lineal, puede ser el uso de polinomio. De esta forma, se reemplaza el modelo lineal con una función de polinomio de grado d (2.11):

$$Y = B_0 + B_1x_i + B_2x_i^2 + B_3x_i^3 + \dots + B_dx_i^d + e_i \quad (2.11)$$

Donde los términos B_0, B_1, \dots, B_d , son los coeficientes de regresión, x los predictores y e_i es el término de error. Los coeficientes pueden ser estimados fácilmente con el uso de

regresión lineal por mínimos cuadrados. Los valores de d no suelen ser mayores de 3 o 4 para evitar sobre ajuste del modelo (Ramasubramanian y Singh, 2019).

2.5.3 Diagnóstico de modelos de regresión

En el diagnóstico del modelo se observa cómo este se ajusta a los datos de entrenamiento (Ramasubramanian y Singh, 2019). Para ello se consideran el p -value de parámetros estimados y el criterio de: Linealidad, que describe la relación entre ambas variables de forma lineal. Para comprobarlo se recurre a calcular los residuos de cada observación acorde al modelo generado y su gráfica debe distribuirse de forma aleatoria en torno a 0. La distribución normal de los residuos se comprueba con el gráfico Q-Q y el test de *Lilliefors*. La Varianza de residuos constante (homocedasticidad) debe ser constante a lo largo del eje X y se comprueba mediante gráficos (*scatterplot*) de los residuos de cada observación. También se recurre a contrastes de homocedasticidad, como el test de *Breusch-Pagan* que analiza si la varianza estimada de los residuos de una regresión depende de los valores de las variables independientes. Si el test-F confirma que las variables independientes son significativas, entonces se puede rechazar la hipótesis nula de homocedasticidad. La identificación de Valores atípicos y de Alta influencia, los que se estudian con detenimiento, pues pueden generar una correlación que realmente no existe, u ocultar una existente. La independencia también es importante de tener en cuenta cuando se trata de mediciones temporales, se detecta si los residuos siguen un patrón o tendencia y como método estadístico, se emplea el test de *Durbin-Watson*. Por último, si el factor de inflación de la varianza (*VIF*), exceden de cinco indica problemas de colinealidad (James *et al.*, 2021; Ramasubramanian y Singh, 2019)

2.5.4 Validación de modelos de regresión

El término validación cruzada corresponde con una estrategia para estimar el error de predicción del modelo. Para ello, a la base de datos de 340 observaciones, se extraen aleatoriamente 200 datos de entrenamiento (60 % de los datos) del modelo y el resto (40 %) para su validación y estimación del error de predicción. Al tratarse de una variable continua se emplea como medida los errores medios al cuadrado (MSE), que consiste en la división del RSS entre el número de observaciones (n) (2.12):

$$MSE = \frac{RSS}{n} \quad (2.12)$$

Una de las principales desventajas de la validación simple es que la estimación del error varía en dependencia de cómo se hayan repartido los datos, entre entrenamiento y validación (James *et al.*, 2021). Sin embargo, lo que no se debe obviar es la necesidad de comprobar el modelo con datos que no formen parte del entrenamiento, para verificar el comportamiento ante nuevas informaciones.

2.6 Analítica predictiva y modelos para análisis espacial

Según García y Orozco (2021), el análisis de elementos del suelo enfrenta grandes retos respecto al análisis de su distribución espacial y requiere de estrategias de muestreo en las unidades mínimas de manejos y la aplicación de métodos estadísticos para procesar la información obtenida.

2.6.1 Ajuste de modelos para el análisis espacial

Los elementos básicos para la predicción espacial transcurren por los análisis exploratorios, donde se busca que los datos se ajusten a una distribución normal. Un análisis estructural que determina la máxima distancia a la que dos muestras están correlacionadas; la predicción mediante el modelo de *kriging* ordinario y la validación

cruzada, donde se selecciona el modelo de menor error (García y Orozco, 2021). Una primera herramienta para estudiar la correlación entre las determinaciones realizadas es el diagrama de dispersión h . En este diagrama, la correlación se visualiza de acuerdo con el nivel de agrupamiento (o dispersión) de la nube de puntos en la gráfica; un mayor agrupamiento implica una mayor correlación.

En diversos estudios geoestadísticos se realiza el análisis de la correlación espacial entre datos puntuales (Bhunja *et al.*, 2018; Piotrowska-Długosz *et al.*, 2019; Wang *et al.*, 2017). La correlación es expresada en términos de semivarianza (Kumar y Sinha, 2018). A través de un análisis exploratorio y posterior construcción del semivariograma experimental; se ajusta un modelo teórico, que será utilizado en la interpolación de la variable. Además, se evalúa la predicción obtenida mediante la validación cruzada.

El semivariograma es la herramienta principal de la geoestadística para la descripción de la variación espacial de un fenómeno. La ecuación usual para construir el semivariograma es por el método de Matheron (2.13) (Oliver y Webster, 2015).

$$\hat{\gamma}(\mathbf{h}) = \frac{1}{2m(\mathbf{h})} \sum_{i=1}^{m(\mathbf{h})} \{z(\mathbf{x}_i) - z(\mathbf{x}_i + \mathbf{h})\}^2, \quad (2.13)$$

Donde $z(\mathbf{x}_i)$ y $z(\mathbf{x}_i + \mathbf{h})$ son los valores observados del indicador estudiado (z) en los sitios (\mathbf{x}_i) y $(\mathbf{x}_i + \mathbf{h})$, $m(\mathbf{h})$ es el número de pares a una distancia h . Al cambiar el valor h se obtiene un *set* de valores de semivarianza. Diversos modelos son utilizados en la geoestadística para ajustarse a los datos del semivariograma empírico. La librería *gstat* de R (Gräler *et al.*, 2016) dispone de varias opciones para emplear acorde al comportamiento del semivariograma experimental.

El ajuste a los modelos teóricos permite extraer diferentes parámetros, posteriormente empleados para la interpolación geoestadística (*kriging*) y que definen el grado y escala de

variación espacial. Estos parámetros son el rango (A_0), el *nugget* (C_0), el *sill* (C_0+C), y la proporción de la varianza explicada por el espacio $\lceil C_0/(C_0+C) \rceil$ (Kumar y Sinha, 2018). Si $\lceil C_0/(C_0+C) \rceil < 0,25$ la variable presenta una fuerte dependencia espacial; entre 0,25 y 0,75 la dependencia espacial es moderada, y mayor o igual a 0,75 la dependencia espacial es débil (Mamat *et al.*, 2014).

Los modelos teóricos se ajustan bajo el criterio de minimizar la suma del cuadrado de los errores (Bivand *et al.*, 2008), según la ecuación (2.14):

$$\sum_{j=1}^p w_j (\gamma(h) - \hat{\gamma}(h))^2 \quad (2.14)$$

Donde $\gamma(h)$ es el valor según el modelo paramétrico y w_j es el peso para ponderar, empleado para el ajuste (Tabla 2.1) (Bivand *et al.*, 2008).

Tabla 2.1 Diferentes pesos para el ajuste de modelos teóricos de semivariograma

<i>Identificación</i>	<i>Peso (w_j)</i>	<i>Observaciones</i>
1	N_j	Estimación: mínimos cuadrados ponderados
2	$N_j / \{\gamma(h_j)\}^2$	(WLS). N _j : Número de pares a la distancia h _j .
7	N_j / h_j^2	γ : Semivariograma
6	1	Estimación: mínimos cuadrados ordinarios (OLS).

Los modelos más comúnmente utilizados (Anexo 3) son: esférico, exponencial, gaussiano y lineal (Gallardo, 2006). En Olea (2006) se consideran, además, de los mencionados (a excepción del lineal) los modelos Wave, Penta-esférico y Cúbico. El modelo Wave se utiliza para el caso de las muestras recolectadas de forma puntual en el año 2016, debido a que el semivariograma experimental mostró un comportamiento similar a este, para los nutrientes asimilables analizados. Los modelos ajustados por los diferentes métodos se evalúan por validación cruzada y se selecciona el mejor ajuste para una predicción espacial.

Los modelos mencionados son isotrópicos, lo que significa que la variabilidad espacial no depende de la dirección; sin embargo, si al modificar la dirección se obtienen cambios importantes en el rango o en la meseta del semivariograma, se está en presencia de anisotropía. En la práctica usualmente se estudian las cuatro direcciones (0° , 45° , 90° y 135°), a las cuales se les estiman los semivariogramas (Gallardo, 2006) y se construye el mapa variográfico. Si los rangos y las mesetas son aproximadamente iguales o no se observa tendencia en el mapa variográfico, no son necesarios los modelos anisotrópicos.

2.6.2 Validación cruzada

La validación de los modelos es una forma de comprobar el efecto de todas las decisiones tomadas en los métodos de estimación de la variable en el espacio. Este método sirve como señal de aviso, donde se identifican y determinan aspectos negativos, como errores excesivos entre valores observados y predichos (Gallardo, 2006). En otras palabras, la validación cruzada permitió evaluar la eficiencia y error del mapa de predicción (Bhunia *et al.*, 2018), para los indicadores evaluados y seleccionar el modelo que produce la mejor predicción. Los parámetros utilizados para esta evaluación, en concordancia con Bhunia *et al.* (2018) y Guan *et al.* (2017) son: la raíz de la media de los errores al cuadrado (RMSE), el cuadrado medio del error de predicción (MSE), el cuadrado medio de las desviaciones (MSDR) y el coeficiente de correlación de Pearson entre las observaciones y la predicción (García y Orozco, 2021).

La técnica de interpolación espacial empleada fue: *kriging* ordinario (KO). Esta selección se basó en el tipo de dato, objetivo perseguido con el análisis, complejidad de la técnica y sus usos en diversos trabajos publicados en literaturas científicas (Castro *et al.*, 2017, García y Orozco, 2021).

2.7 Valoración de perjuicios espacio-temporales del sistema socio-ecológico

Los métodos descritos con anterioridad permiten analizar los perjuicios por el distanciamiento entre un valor potencial, de uno real. Estos perjuicios, en los procesos de soporte de disponibilidad de nutrientes y extracción azucarera, se integran en un índice para el escenario de variabilidad espacio-temporal del sistema socio-ecológico azucarero.

2.7.1 Perjuicio y pérdidas en el proceso extracción azucarera

El distanciamiento antes mencionado, respecto a la variabilidad temporal de la provisión azucarera, se relaciona con las diferencias entre el potencial azucarero del cultivo de la caña de azúcar (expresado como RPC) y la producción obtenida (expresada como azúcar B-96). Al poseer repetidas mediciones en el tiempo, junto a factores correlacionados, se puede realizar un análisis econométrico y probar el ajuste a un modelo de regresión (García *et al.*, 2022), para lo cual sirve de base lo expuesto en el epígrafe 2.5. El cálculo del perjuicio y las ecuaciones utilizadas (2.15 a 2.16), en el caso del procesamiento industrial se describe a continuación:

$$DPRE = (X_i - X_R) \quad (2.15)$$

Donde

DPRE: Diferencia entre potencial de provisión de azúcar y producción real (t a⁻¹)

X_i: Es el Potencial azucarero y X_R: Es el azúcar B-96

$$Potencial (X_i) = Cmi * \frac{RPC}{100} \quad (2.16)$$

C_m: Caña de azúcar molida (t)

RPC: Rendimiento potencial en caña (%)

$$Azúcar B - 96 (X_R) = Cmi * \frac{RB-96}{100} \quad (2.17)$$

RB-96: Rendimiento industrial en base 96(%)

A partir de la diferencia entre provisión azucarera agroindustrial potencial y real se determinó el índice a escala diaria (I_{p-DRPE}) (2.18). Este índice fue utilizado como variable respuesta para el ajuste de un modelo predictivo, según los criterios estadísticos ya expuestos.

$$I_{p-DRPE} = \frac{DPRE * P_A}{C_{mi}} \quad (2.18)$$

I_{p-DRPE} : Índice de perjuicio por diferencia entre provisión azucarera agroindustrial potencial y real (USD t^{-1} de caña molida)

P_A : Precio del azúcar (USD t^{-1} de azúcar).

Los análisis económicos se realizaron bajo la consideración de los precios del mercado internacional en dólares (USD). En el ajuste del modelo predictivo para este perjuicio, se generó una variable aleatoria de precios con media de 467,7, desviación estándar de 112,2, para un intervalo de 213,3 a 797,2 USD t^{-1} de azúcar.

2.7.2 Perjuicio del manejo de fertilizantes por variabilidad a escala sub-campo

Las propiedades químicas del suelo originan diferentes dosis de fertilizantes. La cuestión radica en que no existen aplicaciones variables (hasta la fecha) para el manejo de fertilizantes, a escala de sub-campo en el cultivo de la caña de azúcar y las dosis se deben ajustar a una recomendación única, a nivel de campo. Para el cálculo de la dosis única se considera la necesidad del área de mayor extensión entre los diferentes sitios específicos identificados. Lo que permite determinar la diferencia de aplicar esta, respecto a las necesidades específicas de cada sitio (2.19 y 2.20).

$$CD = NNI * P \quad (2.19)$$

Donde

CD: Costo de la dosis de fertilizantes (USD ha^{-1})

NNI: Necesidad de fertilizante identificada en el sitio específico ($t\ ha^{-1}$)

P: Precio del fertilizante ($USD\ t^{-1}$ de fertilizante)

Así, la determinación de perjuicio por variabilidad espacial (PVE) ($USD\ ha^{-1}$) será:

$$PVE = CD_u - CD_e \quad (2.20)$$

Donde

CD_u : Costo de una dosis única de fertilizantes a aplicar al sitio específico ($USD\ ha^{-1}$).

CD_e : Costo de la dosis de fertilizantes según la necesidad del sitio específico ($USD\ ha^{-1}$).

De esta forma, valores en negativo de PVE significan déficit, mientras que valores positivos representan exceso de fertilizantes y solo donde $CD_u = CD_e$, la dosis es adecuada para el sitio específico.

El precio del fertilizante considerado (superfosfato triple) para cubrir las necesidades de fósforo fue: $531\ USD\ t^{-1}$ de SPT (AZCUBA, 2020).

Para el caso del potasio asimilable se procedió de igual forma, pero se utilizaron, además, los rendimientos agrícolas que inciden en las dosis recomendadas. El precio del fertilizante considerado (cloruro de potasio) para cubrir las necesidades de potasio fue: $1603,03\ USD\ t^{-1}$ de cloruro de potasio (AZCUBA, 2020). En este caso se consideraron dos extremos de rendimiento agrícola, que se emplea para las necesidades de este elemento: uno bajo de $25,4$ a $33,9\ t\ ha^{-1}$ y otro alto de: $143,9$ a $152,4\ t\ ha^{-1}$ (Pérez *et al.*, 2015).

El análisis realizado permite determinar cuánto se distancia la dosis única (obtenida del área de mayor extensión entre los sitios específicos) de las necesidades de cada sitio específico. Sin embargo, se pueden determinar diferentes escenarios respecto al cambio en la dosis única y su relación con cada sitio específico. Este análisis permite llegar a un índice de perjuicio espacial para cada categoría de los nutrientes asimilables del suelo (I_{p-e}) (2.21) como la sumatoria de los excesos y déficit

$$I_{p-e} = \sum_{i=1}^n |PVE_i| \quad (2.21)$$

Donde, i responde a cada sitio específicos encontrados dentro del campo I

2.7.3 Índice de perjuicio de un escenario espacio-temporal

Los perjuicios para un escenario espacio-temporal son dos vertientes de un fenómeno presente en la sucesión de etapas de la agroindustria azucarera. De esta forma, su valoración en los procesos de soporte, dispuso de los resultados de las diferencias entre provisión azucarera agroindustrial, potencial y real, así como de escenarios relacionados con diferentes dosis de fertilizantes para sitios específicos del suelo (2.22). Para una equivalencia en pesos cubanos (CUP), se utiliza la relación de cambio de 120 CUP=1 USD.

$$PEET = \sum_{j=1}^n (DPRE_j * P_A * 0,9) + \sum_{p=1}^m (I_{p-e-P} * A_P * f) + \sum_{k=1}^q (I_{p-e-K} * A_K * f) \quad (2.22)$$

PEET: perjuicio para el escenario espacio-temporal acorde con el año de zafra (USD a⁻¹)

En el caso del perjuicio en el proceso de extracción azucarera, se utilizan 113 días de zafra, con un promedio de 2570,3 t de caña molida; 268,6 t de azúcar; un RPC promedio de 11,6 y las pérdidas totales de 16,0; el precio del azúcar (P_A) en 227,9 USD t⁻¹ de azúcar (AZCUBA, 2020). El factor 0,9 es una penalización con la consideración de que el aprovechamiento del potencial azucarero debe ser un 90 % del RPC. En el caso de la valoración espacial, se utilizan los valores de I_{p-e} de fósforo (I_{p-e-P}) y potasio (I_{p-e-K}), de cada categoría del suelo. Estos se multiplican por las áreas correspondientes (A_p o A_K) (Tabla 2.2) y el factor por adaptación (f). El criterio empleado, se basa en que un 53,1 % y 49,7 % del área, para fósforo y potasio respectivamente, no recibiría la dosis adecuada. Valores que se obtienen del análisis de variabilidad espacial.

El índice de perjuicios espacio-temporales relacionado al volumen de producción de caña de azúcar (I_{p-vp}) queda expresado de la forma siguiente (2.23).

$$I_{p-vp} = \frac{PEET}{V_p} \quad (2.23)$$

Donde:

I_{p-vp} : índice de perjuicio referido al volumen de producción (USD t⁻¹ de caña de azúcar)

PEET: perjuicios para un escenario espacio-temporal anual (USD a⁻¹)

V_p : volumen de producción de caña de azúcar procesada (t a⁻¹)

La lógica seguida responde a la existencia de variabilidades espacio-temporales en los elementos estudiados. El valor de I_{p-vp} expresa un escenario posible para el sistema socio-ecológico azucarero, relacionado con eficiencias en los manejos adaptados a procesos de soporte, lo que concuerda con Rincón-Ruíz *et al.* (2014), sobre el diseño de posibles situaciones como herramienta para mejorar la toma de decisiones en la gestión de un territorio. Para extrapolar los resultados, se selecciona un escenario con dimensiones mayores o iguales a 5,6 y se cuantifica las proporciones de cada categoría del suelo acorde con SERFE (2015). La tabla 2.2 resume las áreas de cada categoría del suelo utilizada.

Tabla 2.2 Áreas por categorías de fósforo y potasio del suelo para la estimación del PEET

Categorías de Fósforo (mg 100g ⁻¹)	Suma de áreas*	Categorías de Potasio (mg 100g ⁻¹)	Suma de áreas*
Alto (≥3,6)	698,9	Medio (10,9≤ <15,5)	1570,4
Medio4 (3≤ <3,6)	224,3	Bajo (7,9≤ <10,9)	1536,3
Medio3 (2,4≤ <3)	1146,1	Muy Bajo (<7,9)	1221,7
Medio2 (1,8≤ <2,4)	613,0		
Medio1 (1,2≤ < 1,8)	842,0		
Bajo (<1,2)	804,2		
Total general	4328,3	Total general	4328,3

*FUENTE: SERFE (2015)

2.8 Conclusiones parciales del Capítulo 2

1. El diagnóstico espacio-temporal abarca diferentes etapas, con una analítica predictiva y una valoración espacio-temporal. Que ejecutadas de forma interconectadas, pueden servir de guía para el estudio de los procesos de soporte y la provisión azucarera agroindustrial.
2. La etapa de analítica predictiva necesita de diferentes criterios para la selección, ajuste y validación de los modelos a utilizar en la predicción de indicadores estudiados.
3. En los datos temporales se utiliza el análisis de series de tiempo para el pronóstico de la provisión azucarera agroindustrial. Mientras que los modelos de regresión se utilizan en las determinaciones de relaciones causales.
4. Los datos espaciales se describen mediante la construcción de semivariogramas experimentales y ajuste de modelos teóricos, para la predicción espacial mediante el *kriging* ordinario.
5. Se describe un procedimiento para la determinación de los perjuicios relacionados con un escenario espacio-temporales, donde se considera el distanciamiento entre la provisión azucarera agroindustrial potencial y real, así como los excesos y déficit de fertilizantes asociados al manejo de adaptación a sitios específicos.

CAPÍTULO 3. RESULTADOS Y DISCUSIÓN

En este Capítulo se exponen los resultados arribados tras el diagnóstico espacio-temporal, en base a la analítica predictiva y la valoración de los diferentes indicadores biofísicos estudiados, en el sistema socio-ecológico azucarero. Se presentan los diferentes modelos predictivos, sus validaciones y predicciones; así como los conflictos y perjuicios, relacionados a variabilidades espacio-temporales en procesos de soporte, de disponibilidad de nutrientes del suelo y extracción azucarera.

3.1 Resultado del análisis exploratorio

La provisión azucarera, expresada como kilogramos de azúcar por tonelada de caña molida (kg t^{-1}), a partir de las informaciones recopiladas y según un análisis de series de tiempo, se puede descomponer en cuatro gráficos. Estos recogen una serie de componentes relacionados con las variabilidades temporales (Fig. 3.1).




Figura 3.1 Descomposición de la serie de tiempo

El primer gráfico (de abajo hacia arriba) denominado como componente aleatorio, es también llamado ruido blanco; se caracteriza por fluctuaciones erráticas sin un patrón

definido alrededor de una media constante (Ruiz, 2018). El segundo en ese orden corresponde a la variación estacional, un patrón de cambio regular que se completa dentro de un año y se repite en base similar (Krispin, 2019). El tercero, evidencia la tendencia de la variable estudiada a largo plazo (Montes *et al.*, 2016) y en este caso se ha caracterizado por un decrecimiento de la provisión azucarera. El cuarto, responde a los valores de la serie de tiempo para el período observado.

Los servicios ecosistémicos se expresan a diferentes escalas de análisis (Grunewald *et al.*, 2015). Escalas mayores permiten observar tendencias generales; mientras que en escalas menores se observan mayores detalles para los procesos y manejos que inciden en la provisión azucarera. Lo cierto es que el sistema socio-ecológico azucarero está marcado por la existencia de variabilidades espacio-temporales de suelo, cultivo y procesamiento.

La extracción de sacarosa, como última etapa de la producción de azúcar, presenta un comportamiento en forma de campana, con menores valores al inicio de zafra, un aumento a mediados y una disminución hacia el final. Sin embargo, también se presentan variaciones dentro de cada mes de zafra (Fig. 3.2). Este comportamiento se relaciona con el ciclo vegetativo del cultivo y con la eficiencia industrial. También, la combinación de diferentes cultivares de caña de azúcar y composición de cepas pueden incidir en variaciones del rendimiento industrial (Chiang *et al.*, 2018).

Con frecuencia las variabilidades espacio-temporales son resultados de diversas causas, predecibles o no y en el caso de estudio, relacionadas a las etapas agrícolas e industrial. Cada mes de una zafra está condicionado por lo obtenido en los diferentes campos de cultivo, como consecuencia de los manejos agrícolas, momento de cosecha y condiciones climáticas. También, la eficiencia del proceso de extracción de sacarosa, ocasiona incrementos o decrecimientos en la provisión azucarera agroindustrial (Fig. 3.2).

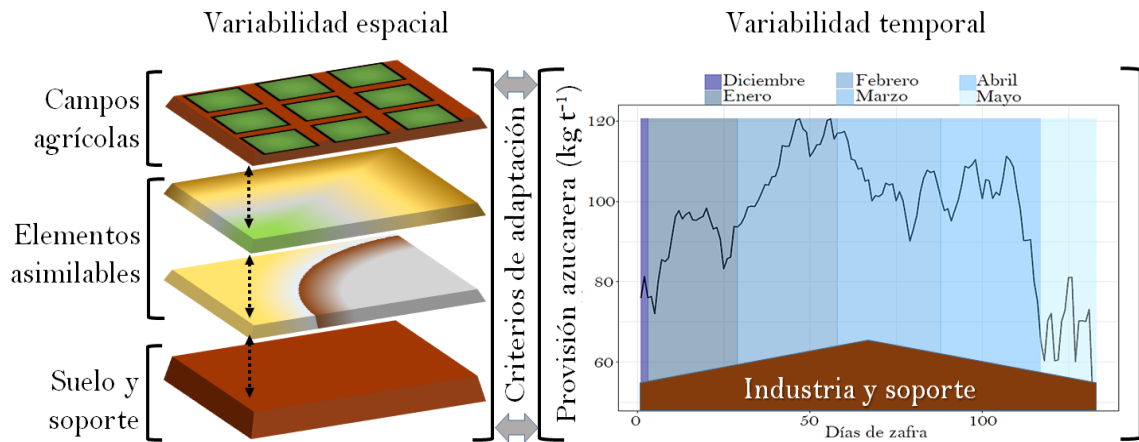


Figura 3.2 Variabilidad espacio-temporal en una zafra azucarera

El desarrollo tecnológico y uso de maquinarias ha permitido la gestión de mayores extensiones de tierras, en la preparación de suelo, manejo de cultivares y técnicas de riego. Sin embargo, la disponibilidad de nutrientes, considerada un proceso de soporte del suelo (Grunewald *et al.*, 2015), no se comporta en forma homogénea y necesita de la identificación de propiedades, para llegar a manejos adaptados a sus variabilidades espaciales (García y Orozco, 2021).

Los indicadores de procesos de soporte y provisión azucarera agroindustrial se expresan para un espacio-tiempo, en cuantías variables. Por un lado, existe la necesidad de definir sitios específicos para un manejo adaptado a los nutrientes del suelo y en correspondencia con una agricultura de precisión. Mientras que la expresión variable en la provisión azucarera agroindustrial requiere del pronóstico de su comportamiento y el establecimiento de las relaciones causales con los predictores importantes. El diagnóstico de estos elementos puede aportar conocimientos sobre las variabilidades espacio-temporales. Según Grunewald *et al.* (2015), estas necesitan ser comprendidas y valoradas, para una adecuada consideración de los servicios ecosistémicos en la toma de decisiones.

3.1.1 Descripción estadística de los datos colectados

En la tabla 3.1 se puede observar la caracterización de los indicadores, donde se expresan los valores recopilados y también los calculados (SPA y DPRE) que han sido utilizados en los análisis causales para la provisión azucarera.

Tabla 3.1 Descripción estadística de los indicadores recopilados a escala diaria

	SPA	RPC	PERD_T	A_RPC	ANP	ME	P_MIEL_FINAL	RECB	DPRE
N	340	340	340	340	340	340	340	340	340
X	101,4	11,9	18,5	85,4	71,1	9,9	41,3	81,5	4,0
M	101,6	12,0	18,4	86,2	74,7	9,3	41,1	81,7	3,7
DS	8,9	0,8	3,1	6,2	20,2	2,0	3,5	3,1	1,8
CV	8,8	7,0	17,0	7,3	28,4	19,8	8,4	3,9	44,7

N: tamaño de la muestra; X: media; M: mediana; DS: desviación estándar;

CV: coeficiente de variación

La tabla 3.1 muestra las medidas de tendencia central y dispersión de los datos. Acorde con el coeficiente de variación, las dispersiones mayores se encuentran en las variables ANP, ME, PERD_T; la primera (ANP) responde a las diferentes cuantías de tallos de caña de azúcar provisionada para su molienda en la industria; mientras que la segunda (ME) responde a los niveles de materias extraña que poseen los tallos que son procesados. Ambas variables denotan heterogeneidad en la materia prima que llega a la industria. La tercera variable (PERD_T) corresponde a variaciones en factores dentro de la industria que originan pérdidas en el azúcar producido. Navarro y Rostgaard (2014) han encontrado que el porcentaje de extracción se ve afectado de 87,37 % a 83, 3%, para el intervalo de 0 a 25 % de materia extraña. Sin embargo, el mayor valor del coeficiente de

variación lo recoge la variable DPRE, que expresa que las diferencias entre potencial azucarero y el azúcar real obtenido son variables.

Para los datos espaciales, se encontró una dispersión respecto a la media con coeficientes de variación, entre 80,08% y 110,05 % en el caso del fósforo asimilable. Mientras que para el potasio fue de 39,04 % y 63,95% (Tabla 3.2).

Tabla 3.2 Descripción estadística de los indicadores del suelo

Año	Fósforo asimilable				Potasio asimilable			
	2015	2016	2019	2022	2015	2016	2019	2022
N	671	100	100	100	671	100	100	100
X	2,15	2,80	2,32	1,68	10,62	8,62	6,15	6,74
M	1,60	2,31	1,62	1,32	9,23	8,16	5,24	6,31
DS	2,35	3,08	1,86	1,62	6,63	3,37	3,93	2,76
CV	109,59	110,05	80,08	96,67	62,37	39,04	63,95	40,98

N: tamaño de la muestra; X: media; M: mediana; DS: desviación estándar;

CV: coeficiente de variación

Los mayores valores de CV son de los datos del suelo. La disponibilidad de nutrientes, proceso de soporte del cultivo en la etapa de campo, es abierto e incidido por múltiples factores de origen natural y antrópico. En otras palabras, los altos coeficientes de variación son reflejo de la variabilidad del suelo; coeficientes de variaciones similares son encontrados en Fu *et al.* (2010).

Según Piotrowska-Długosz *et al.* (2019), aunque los suelos presenten el mismo origen, estos difieren en sus propiedades físicas y químicas. El paisaje y los manejos pueden generar cantidades desiguales de nutrientes en el suelo, incluso dentro de los campos de

un mismo cultivo (Logsdon y Cole, 2018). Por ello, las evaluaciones operacionales se deben efectuar a escala compatible con el ámbito de acción de los actores involucrados y de las posibles decisiones a tomar (Paruelo *et al.*, 2010).

3.2. Resultados de la analítica predictiva

3.2.1 Series de tiempo y variabilidad temporal de la provisión azucarera

La base de datos recopilada para el período de 2004 a 2021 fue analizada en base a sus trimestres y se compararon diferentes modelos (Anexo 4). La consolidación en trimestre de la serie respondió, en primera instancia, al interés de reflejar las variabilidades estacionales que suceden en las zafras azucareras. También al comportamiento irregular de la misma, pues solo se comprende en un grupo de meses de cada año.

La realización del test de *Dickey-Fuller*, igual a 6,13 para un *lag* de 4 y un *p-value* igual a 0,11, no encuentra evidencias para rechazar la hipótesis nula de que la serie es no estacionaria, por lo que una derivación es de utilidad para el modelado de la misma. El modelo seleccionado ARIMA (0, 1, 1) (2, 1, 2) [4] se puede observar en la figura 3.3.

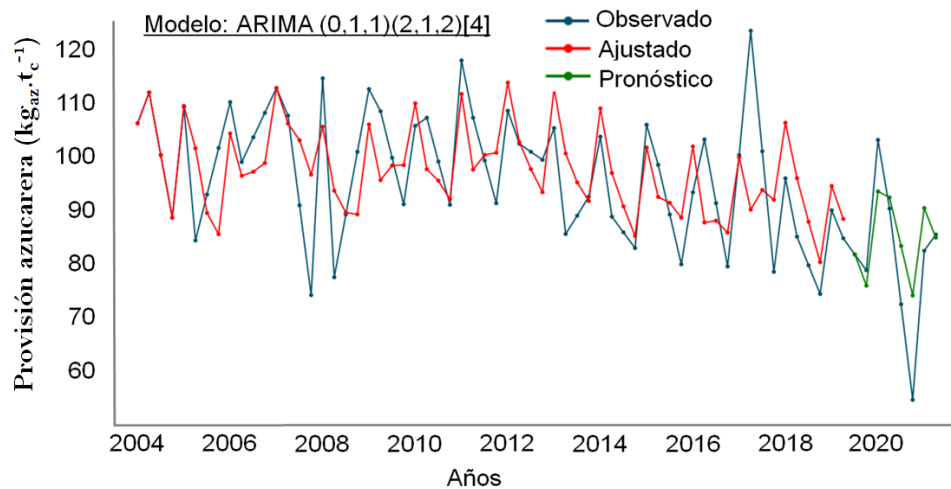


Figura 3.3 Modelado de la serie de tiempo con un modelo ARIMA

Los pronósticos que se realicen mediante el uso de estos métodos tienen la premisa de que se mantendrá la tendencia encontrada, para lo cual se obtienen valores que son bastante precisos en el corto plazo (Contreras-Juárez *et al.*, 2016). Pero se requiere del cumplimiento de los requisitos para considerar que el modelo ARIMA (0, 1, 1) (2, 1, 2) [4] es útil para realizar el pronóstico de la provisión azucarera.

Como parte de la selección del modelo ARIMA (0, 1, 1) (2, 1, 2) [4] está la validación y análisis de sus residuos. Es poco probable que los pronósticos coincidan totalmente con el futuro; una vez llegado este punto. Solo se pueden intentar que los inevitables errores sean tan pequeños como sea posible (Delgadillo-Ruiz *et al.*, 2016). En la tabla 3.3 se recogen los indicadores de ajuste del modelo para datos de prueba y de entrenamiento.

Tabla 3.3 Indicadores de ajuste del modelo

	<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>
Set de entrenamiento	-0,5	9,1	6,8	-1,3	7,3
Set de prueba	-3,4	9,0	6,6	-6,0	9,5

Cada medición de error tiene una interpretación diferente que ofrece información sobre el pronóstico o el modelo empleado. ME y MPE dan información sobre el sesgo esperado en el pronóstico; es decir, qué tan sub-estimado o sobre-estimado estará el pronóstico en promedio, dependiendo si ME es positivo o negativo, respectivamente. Sin embargo, no siempre proporcionan una idea de la precisión, debido a que los errores negativos con los positivos se cancelan unos con otros y podría darse el caso de que un pronóstico muy malo arrojará un ME o MPE con valor de cero o muy cercano a cero. Por otro lado, MAE y MAPE indican el tamaño del error del pronóstico, pues consideran sólo la magnitud del error (valor absoluto), e indica la exactitud esperada del pronóstico. Una proporción del error baja en el entrenamiento, junto con una proporción del error alta en la comprobación

para los valores de MAPE, es indicio de sobre ajuste del modelo. En este caso la diferencia es de 2,2 %; en Alonso (2021) se aceptan modelos con diferencia de MAPE de 5,9 y 7,1 %. Todos estos parámetros estadísticos junto al RMSE ayudan a seleccionar el mejor modelo, acorde con los menores valores encontrados.

Además de esto, se considera el comportamiento de los residuos como parte de la valoración integral que se debe realizar en la construcción de un modelo útil (Fig. 3.4).

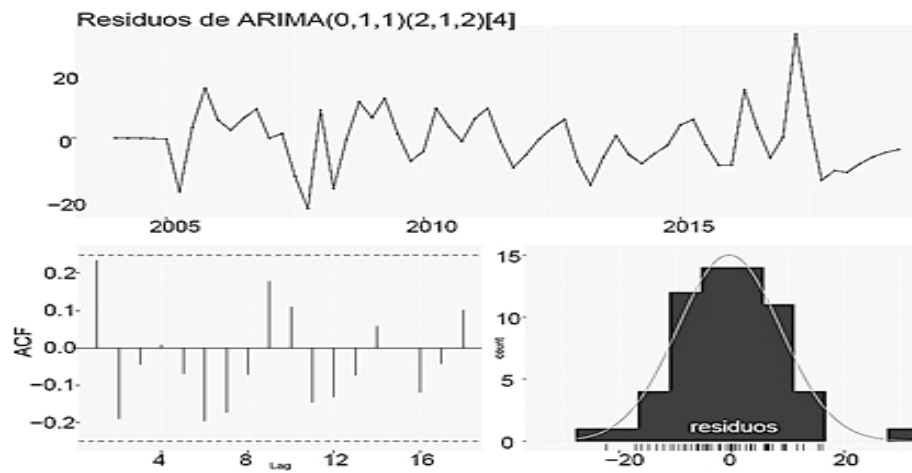


Figura 3.4 Comportamiento de los residuos de modelo ARIMA ajustado

El gráfico de ACF de los residuales sugiere que las autocorrelaciones se encuentran dentro del intervalo de confianza; es decir, son cercanas a cero. Cuando esto sucede, indica que los residuales no se desviaron significativamente de un proceso de ruido blanco, y son puramente aleatorios (Luis-Rojas *et al.*, 2019), lo que es positivo para el modelo ajustado. Sin embargo, se consideran además las pruebas para los residuos de *Lilliefors*, *Box-Pierce* y *Ljung-box*, las cuales se comportan con valores de p-value mayores que 0,05 (tabla 3.4). El modelo seleccionado se compone de un coeficiente de media móvil (MA1) en la parte regular de la serie; mientras que en la parte estacional se tienen dos coeficientes autorregresivos (SAR1 y SAR2), así como dos de media móvil (SMA1 y SMA2). Se expone también el error estándar de cada uno (s.e.).

Tabla 3.4 Pruebas de requisitos y coeficientes del modelo

		<i>Test de los residuos</i>					
		<i>Test: Lilliefors</i>	<i>Test: Box-Pierce</i>	<i>Test: Ljung-Box</i>			
		<i>p-value</i> = 0,85	<i>p-value</i> = 0,06	<i>p-value</i> = 0,05			
		<i>Coeficientes del modelo</i>					
		<i>MA1</i>	<i>SAR1</i>	<i>SAR2</i>	<i>SMA1</i>	<i>SMA2</i>	
		-0,79	-0,79	-0,21	-0,14	-0,57	
		s.e	0,19	0,34	0,18	0,34	0,30
		Sigma ² estimado de 98,37: <i>log likelihood</i> de -213,04					
		Criterios: AIC=438,09 AICc=439,77 BIC=450,35					

ARIMA (0,1,1)(2,1,2)[4]

El modelo ARIMA (0,1,1)(2,1,2)[4] presentó el mejor comportamiento entre los diferentes tipos que fueron probados (Anexo 4). Pero el interés de este método de pronóstico no está solo en la construcción de un modelo específico, sino en el análisis de las propiedades de la serie de tiempo, explicada por valores pasados o rezagados de sí misma y por los términos de error estocásticos (Gujarati y Porter, 2010). De acuerdo Cabrera *et al.* (2015), al permitir evaluar los procesos mediante herramientas estadísticas, se puede mejorar los procesos de toma de decisiones.

3.2.2 Relaciones causales y variabilidad temporal de la provisión azucarera

Además del análisis de series de tiempo, se determina la relación con factores que inciden de manera positiva o negativa en la provisión azucarera. Para ello se realiza el estudio de las variabilidades temporales a escala diaria y se evalúa la correlación con los indicadores de eficiencia del proceso industrial (Fig. 3.5). Múltiples indicadores dentro del proceso industrial se pueden correlacionar con la provisión azucarera. Sin embargo, también puede

existir correlación entre ellos, lo que origina información redundante en la construcción del modelo y causa inflación de su error estándar (Ramasubramanian y Singh, 2019). Por ello, el mejor modelo no es de mayor cantidad de variables predictoras, sino el que posea las más representativas (García *et al.*, 2022).

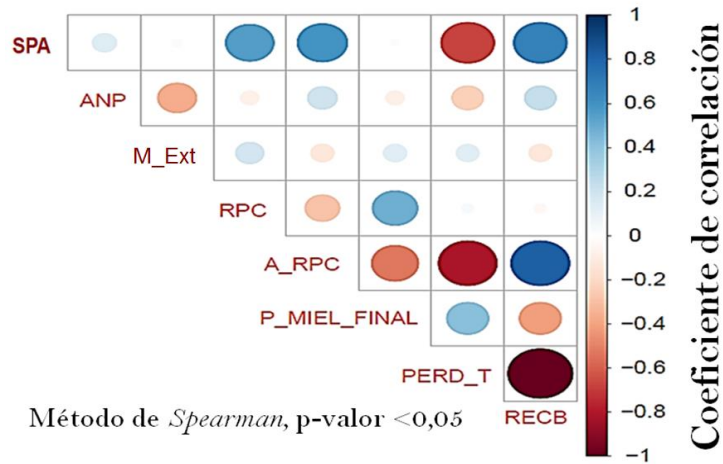


Figura 3.5 Correlación entre indicadores del proceso de extracción de sacarosa

Se considera, en primera instancia, las pérdidas totales (PERD_T) como sumatoria de todas las pérdidas, además, este predictor presenta una marcada correlación con el recobrado, lo que permite excluir este último al igual que el aprovechamiento de RPC. De esta forma se procede con los predictores que se mostraron en la figura anterior (Fig. 3.5), a excepción del recobrado (RECOB) y A_RPC para predecir el indicador de provisión azucarera. El comportamiento de estas variables se exponen en el Anexo 5.

La mejor combinación de predictores se selecciona mediante los criterios estadísticos de R^2 ajustado y C_p . La selección de variables permite elegir el subgrupo de predictores y establecer una relación adecuada de bias-varianza, además de evitar un sobre o bajo ajuste del modelo (Ramasubramanian y Singh, 2019; Zimmerman, 2020). Los mejores modelos ajustados a los datos, según los criterios evaluados, fueron los que utilizaron dos predictores (Fig. 3.6 a y b); se puede observar en ambos gráficos que la mejoría por encima

de dos predictores es poca. En busca de un modelo más simple (parsimonia) se determina sí, mediante dos predictores, se puede obtener un modelo para predecir el comportamiento de la provisión azucarera.




Figura 3.6 Relación del R^2 ajustado (a) y el valor Cp (b) con el número de predictores

Los modelos predictivos necesitan de la selección de variables acorde a la finalidad que se requiera. La selección de variables, mediante criterios estadísticos, permite elegir el subgrupo de predictores y establecer una relación adecuada de bias-varianza, además de evitar sobre o bajo ajuste del modelo (Ramasubramanian y Singh, 2019; Zimmerman, 2020). Según el método de selección (*best subset selection*), como fue mostrado, los predictores de mayor significación para el caso evaluado fueron RPC y PERD_T.

El RPC es resultado de factores de afuera de la industria como la variedad, edad, época del año y condiciones del cultivo (Martínez y De León, 2012). Mientras que las pérdidas industriales se ven influenciadas por factores dentro de la industria como: condiciones de la fábrica, eficiencia y disciplina del proceso industrial (Martínez y De León, 2012); autores como Roy y Chandra (2020) también destacan, que el tiempo después de cosechado el cultivo, puede incidir en bajas o altas cuantías de pérdidas de azúcar, mientras que Navarro y Rostgaard (2014) explican que las materias extrañas pueden incrementar las pérdidas en bagazo, así como una disminución de su poder calórico, reducir la pureza

del jugo mezclado, aumentar las pérdidas en la miel final y, de forma general, disminuir la producción de azúcar.

En resumen, las condiciones de la caña de azúcar a la entrada del central y su procesamiento afectan el servicio de provisión azucarera. Por tal motivo, se concuerda con los indicadores RPC y PERD_T como predictores en un modelo de regresión lineal para describir la variabilidad temporal del servicio de provisión azucarera. En la tabla 3.5 se recoge la significancia del modelo, que es capaz de explicar el 85 % de la variabilidad observada en el servicio de provisión azucarera (R^2 de 0,85). El test F muestra que es significativo ($p\text{-value} < 2,2 e^{-16}$). Sin embargo, para que el modelo pueda ser utilizado, debe cumplir, además, con otros criterios estadísticos.

Tabla 3.5 Coeficientes del modelo lineal

	<i>Estimación</i>	<i>Error</i>	<i>valor T</i>	<i>Pr(> t)</i>	<i>Sig.</i>
(Intercepto)	60,30	3,66	16,37	$< 2e^{-16}$	***
RPC	6,64	0,30	22,99	$< 2e^{-16}$	***
PERD_T	-2.06	0,07	-26,09	$< 2e^{-16}$	***

Significancia: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 '.' 1

Error estándar residual: 3,5 con 197 grados de libertad

R^2 múltiple: 0,85, R^2 ajustado: 0,85

Estadígrafo F: 569,1 en 2 y $p\text{-value} < 2,2e^{-16}$

De acuerdo con lo que establece Ramasubramanian y Singh (2019), el modelo fue comprobado con datos no utilizados en su entrenamiento, mientras que para su diagnóstico se comprobó la significancia de parámetros estimados, normalidad, autocorrelación, homocedasticidad, puntos influyentes y multico-linealidad. El diagnóstico del modelo es realizado mediante pruebas estadísticas y comportamiento gráficos (Tabla 3.6).

Tabla 3.6 Validación de las condiciones del modelo

Prueba estadística	Método	Parámetros
Prueba de normalidad	<i>Lilliefors</i>	$D = 0,039$; $p\text{-value} = 0,62$
Residuos estandarizados	<i>Breusch-Pagan</i>	$BP = 2,18$; $df = 2$; $p\text{-value} = 0,34$

Tanto en la prueba estadística como en el gráfico cuantil-cuantil (Fig. 3.7), no se encontraron evidencia de que los residuos no sigan una distribución normal. Respecto a la homogeneidad de varianza, la prueba de *Breusch-Pagan* arrojó un valor de la probabilidad de 0,34, por lo que se considera que se tiene una banda “casi” rígida. En la prueba de *Durbin-Watson* no se encontraron evidencias de autocorrelación, donde el estadístico d fue de 2,11 y el $p\text{-value}$ de 0,36. También se obtienen valores VIF (1,003) para ambos predictores por debajo de 5, por lo que no existen problemas de colinealidad, ni presentan una inflación de varianza marcada. Además de lo expuesto, en la figura 3.7 se muestran cuatro gráficos que corroboran los resultados de los test estadísticos.

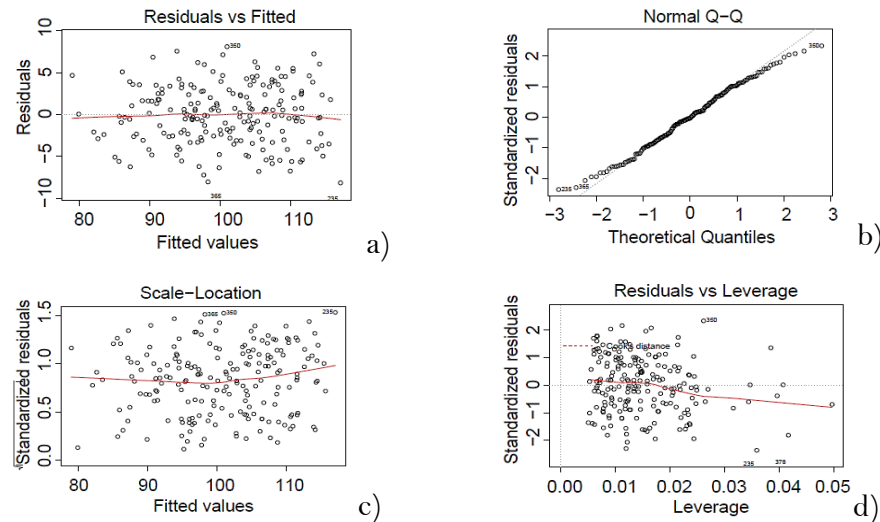


Figura 3.7 Validación de condiciones del modelo

En el gráfico (Fig. 3.7 a; *residuals vs fitted*) no se observó ningún patrón, lo cual es indicativo de que no existe heterocedasticidad. En la figura 3.7 b (*normal QQ*), se

diagnosticó la normalidad y los puntos se encontraron cerca de la diagonal. La figura 3.7 c (*scale-location*) también es indicativa para la heterocedasticidad y lo ideal es encontrar una pendiente nula (Ramasubramanian y Singh, 2019). Mientras que la figura 3.7 d (*residuals vs leverage*) permite detectar valores atípicos o influyentes. En este, se representó los residuos estandarizados en función del valor de influencia o *leverage*, así como la distancia *Cook* para valores influyentes; que al no poseer valores elevados, no existen evidencias de un impacto regular en la línea de la regresión estimada (Nwanganga y Chapple, 2020). Un último aspecto considerado es la validación cruzada, donde el cuadrado medio del error (MSE) obtenido fue de 14,4; mientras que en la figura 3.8 se observa la relación entre los valores observados y la predicción del modelo para los datos de prueba. Es de esperar que a medida que los puntos se acerquen a la línea recta, mejor será la predicción del modelo (James *et al.*, 2021).




Figura 3.8 Relación entre valores de predicción vs observados en los datos de prueba

Se satisfacen, entonces, las condiciones de normalidad, autocorrelación y no se presenta una inflación de varianza marcada, para los predictores; tampoco se encontraron evidencias contra la homogeneidad de varianza. Entonces, la provisión azucarera y su relación con los predictores: rendimiento potencial en caña (RPC) y pérdidas totales en la industria (PERD_T), puede ser modelada por un modelo de regresión lineal; cuya expresión matemática es: $\text{Provisión azucarera} = 60,30 + 6,64 * \text{RPC} - 2,06 * \text{PERD}_T$

Este modelo es capaz de explicar el 85,1 % de la variabilidad observada en la provisión azucarera (R^2 de 0,85). El test F muestra que es significativo (p -value: $< 2.2 \cdot 10^{-16}$). Se satisfacen las condiciones de normalidad, autocorrelación y no se presenta una inflación de varianza marcada, con un VIF de 1,003 para ambos predictores. Tampoco se encontraron evidencias contra la homogeneidad de varianza, con un valor de probabilidad de 0,34 en la prueba de *Breusch-Pagan*.

Los resultados encontrados, además de considerar a los modelos válidos para las valoraciones biofísicas del servicio de provisión azucarera, denotan que las predicciones resultan un proceso complejo de ajuste, identificación de errores y validación. En la práctica, cuando se asume un modelo lineal, casi siempre es una aproximación de realidad y existe una fuente adicional de error, potencialmente asociado al sesgo del mismo. Incluso, aunque se conozca los valores reales $\beta_0, \beta_1, \dots, \beta_p$, los valores de respuesta no pueden ser predichos perfectamente, porque existe un error aleatorio del modelo (James *et al.*, 2021).

3.2.3 Análisis de la variabilidad espacial de fósforo y potasio en el suelo

Los manejos que inciden en los nutrientes del suelo, mediante la incorporación de elementos como el fósforo y el potasio, contribuyen a mitigar las extracciones que realiza el cultivo en áreas de producción agrícolas. Los análisis geoestadísticos permiten la delimitación de sitios específicos para realizar estas incorporaciones al suelo. Sin embargo, se necesitan tecnologías de dosis variables, para materializar los manejos adaptados a las variabilidades espacio-temporales de las propiedades del suelo. La inclusión de los servicios ecosistémicos necesita también de análisis espaciales para que las valoraciones, toma de decisiones y manejos del sistema socio-ecológico azucarero se puedan adecuar a los estados y tendencias de propiedades del suelo.

Al realizar la prueba de *Lilliefors* (Anexo 6), se comprueba que los datos originales no se ajustan a una distribución normal. Por ellos se realizó una transformación logarítmica de los mismos, para lograr cumplir con este requisito. Resultado similar fue encontrado por Bogunovic *et al.* (2014) y Vasu *et al.* (2017) para diferentes propiedades del suelo.

En el Anexo 7 se observan los histogramas de frecuencia de la variable original, con un comportamiento asimétrico que corresponde a la falta de ajuste a una distribución normal. Los histogramas de frecuencia de la variable transformada evidencian una mejora en el ajuste. La mejora o no en el ajuste a una distribución normal, también se observa en los gráficos cuartil-cuartil, tanto para las variables originales como para las variables transformadas (anexo 8). De los valores transformados, solo el caso del fósforo asimilable (en el muestreo de suelo del año 2016) exhibe un *p-value* de 0,02 y no pasa el test de *Lilliefors*, pero presenta mejoría respecto a los valores sin transformar. Se modela con la transformación logarítmica, pues se acerca a la distribución normal, lo que coincide con las investigaciones de otros autores (Bogunovic *et al.*, 2014; Zhang, 2006).

Un aspecto básico que debe ser analizado es la relación entre pares de valores a diferentes distancias. Mediante métodos clásicos y geoestadísticos se pueden entender las asociaciones espaciales de nutrientes del suelo en la agricultura y desarrollar prácticas de manejos por sitios específicos (Bhunja *et al.*, 2018).

La exploración para diferentes distancias entre pares de valores, permite analizar las de máxima correlación, provee los elementos para el ajuste del semivariograma y propone valores para los sitios no muestreados en los campos (Tola *et al.*, 2017). En esta investigación (muestreo de suelo en el año 2015), se obtiene que la correlación mas alta entre pares de valores, para el caso del fósforo asimilable, fue de 60 a 80 m, mientras que, para el potasio asimilable, se encontró entre 40 a 80 m (Anexo 9).

Seguido a esto se realiza el análisis estructural con la construcción de los semivariograma. En la figura 3.9 a, se observa el modelo ajustado y en el Anexo 10 aparecen los diferentes modelos evaluados para fósforo asimilable. Se selecciona el que presenta los menores errores y mayor coeficiente de correlación tras la validación cruzada (WLS 1). Los valores de correlación entre la variable observada y los valores predichos por el modelo no son elevados (Anexo 10), este aspecto es encontrado en Guan *et al.* (2017) y se corresponden con los muestreos de suelo no probabilísticos (Veronesi *et al.*, 2014).

Es importante destacar que la comparación entre modelos a partir de la suma del cuadrado de los errores (SCE), se realiza para los mismos métodos de ajuste de curva. La selección del modelo exponencial (Fig. 3.9) para valores de fósforo del suelo coincide con Bhunia *et al.* (2018) y Bogunovic *et al.* (2014).

El rango, así como los parámetros *sill*, *nugget*, de los diferentes semivariograma dan mayor o menor ajuste a las predicciones espaciales mediante *kriging* ordinario. El semivariograma provee una herramienta cuantitativa simple y potente para la valoración espacial de variabilidades (Paterson *et al.*, 2018). El rango obtenido para el fósforo asimilable del suelo fue de 235 m y se muestra una dependencia espacial moderada de 0,69 (Fig. 3.9 a).

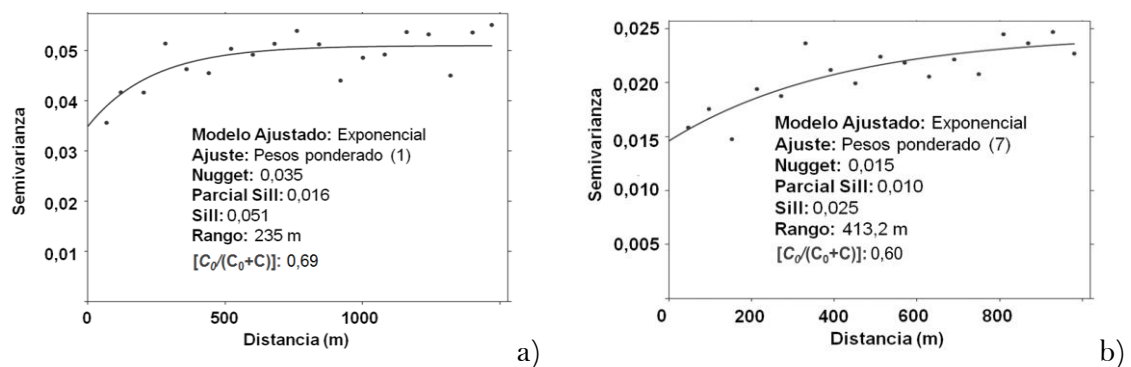


Figura 3.9 Semivariograma ajustado para fósforo (a) y potasio (b) en el suelo

En Bogunovic *et al.* (2014) se obtuvo un rango de 201,1 m; por su parte el rango encontrado por Fu *et al.* (2010) con un modelo esférico, fue de 264 m, mientras que en Vasu *et al.* (2017) el rango fue de 1160 m para este elemento.

Los diferentes modelos evaluados para el potasio asimilable del suelo se observan en el Anexo 11, mientras que el modelo seleccionado se observa en la figura 3.9 b. Al igual que el caso anterior, se selecciona el modelo exponencial que presenta los menores errores determinados y mayor coeficiente de correlación tras la validación cruzada. Para este caso, ajustado por pesos ponderados, pero por el método (WLS 7). La selección del modelo exponencial para valores de potasio del suelo coincide con Bhunia *et al.* (2018); Bogunovic *et al.* (2014); Fu *et al.* (2010) y Guan *et al.* (2017).

El rango obtenido para el potasio asimilable del suelo fue de 413,2 m (Fig. 3.9). En Fu *et al.* (2010), el valor para este parámetro fue de 300 m, en Bogunovic *et al.* (2014) se encontró uno de 1153,6 m; Bhunia *et al.* (2018) hallaron un rango de 1210 m; mientras que Vasu *et al.* (2017) 1291 m para este elemento. La naturaleza de los datos, es decir, la forma en que son colectados, el área que estas representan, el tipo de cultivo y los tipos de suelo pueden incidir en disimiles patrones espaciales y diferentes distancias a la cual los pares de muestras de suelo están correlacionadas (Gallardo, 2006; Fu *et al.*, 2010; Bogunovic *et al.*, 2014).

Las áreas monocultivadas con caña de azúcar mostraron poca relación entre los pares de muestras, más allá de los límites de las unidades mínimas de manejos del cultivo. Es decir, los resultado encontrados evidencian la necesidad de diagnosticar los niveles de fósforo y potasio asimilables del suelo dentro de cada unidad mínima de manejo, junto a la necesidad de que en las áreas superiores a 5 ha se recolecten más muestras acorde a la metodología empleada. El análisis espacial contribuye a lograr manejos adaptados a las características

variables del agrosistema y a superar los límites de diversos estudios existentes sobre los servicios ecosistémicos del suelo, que se enfocan solo en los propios servicios y obvian las complejas interrelaciones de procesos subyacentes. De ahí, la importancia de valorar los servicios ecosistémicos provenientes del suelo, entre otros aspectos, en la investigación en campo y el desarrollo de modelos espaciales explícitos (Su *et al.*, 2018).

Un último aspecto, antes del uso del modelo de semivariograma en el modelo de interpolación espacial de *kriging* ordinario, es evidenciar la existencia de anisotropía. Como se observa en el Anexo 12, no se aprecian tendencias hacia ninguna dirección, en ambos nutrientes evaluados; por lo que se utilizan en la interpolación, los modelos previamente obtenidos.

3.2.4 Variabilidad espacial a menor escala de análisis

El cambio en la escala y forma de muestreo incide en los rangos de distancia para los nutrientes fósforo y potasio asimilables, donde se evidencia la existencia de variabilidades dentro de las dimensiones de 5,6 ha. Se obtiene que la correlación mas alta entre pares de valores, para el caso del fósforo asimilable, fue de 0 a 10 m, mientras que, para el potasio asimilable, se encontró entre 20 a 25 m para esta escala de análisis (Anexo 9). En el Anexo 13 se recogen los modelos que se ajustaron al semivariograma experimental para el fósforo. Se observa en la figura 3.10 que los puntos del semivariograma experimental presentan oscilaciones, lo que es característico del modelo Wave.

Para el potasio asimilable también se identificó una disminución en el rango de distancia (figura 3.10 b), que evidencian las variabilidades espaciales dentro de las dimensiones de 5,6 ha. Los diferentes modelos que se ajustaron al semivariograma experimental (Anexo 14) fueron: Exponencial, Esférico, Lineal y Wave, pero este último mostró el mejor ajuste

a los datos. Según Neto *et al.* (2018), el modelo Wave tiene aplicaciones potenciales para las Ciencias Ambientales, las Geociencias y las Ciencias del Suelo.

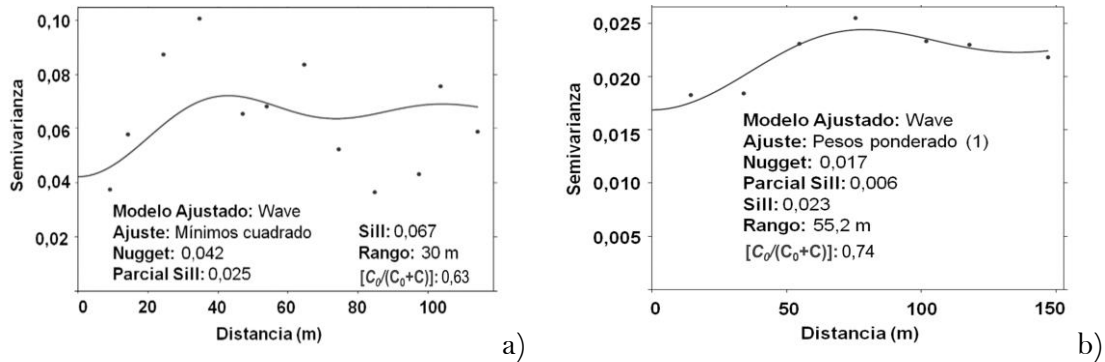


Figura 3.10 Semivariograma a menor escala para fósforo (a) y potasio (b) en el suelo

La dependencia espacial determinada por la relación *nugget/sill* fue moderada y se encontró entre 0,25 y 0,75, lo que puede estar relacionado con factores internos y externos, como formación del suelo y aplicaciones de fertilizantes (Reza *et al.*, 2019). Otros investigadores han realizado similar inferencia sobre la dependencia espacial (Gao *et al.*, 2019; Rahul *et al.*, 2019). En los análisis de las estructuras espaciales se encontró que el potasio presentó un mayor rango de distancia que el fósforo asimilable, para ambos sistemas de muestreo del suelo, en las áreas evaluadas; esto concuerda con Fu *et al.* (2010) y Bogunovic *et al.* (2014); mientras que en los trabajos de Bhunia *et al.* (2018), Bogunovic *et al.* (2017) y Dai *et al.* (2018), el fósforo es el que presenta mayor distancia a la cual las muestras están correlacionada. Estas referencias no son concluyentes sobre la existencia de una dependencia específica, o sea, si siempre el rango de fósforo va a ser mayor que el de potasio o viceversa. Lo que si se considera es la incidencia del tipo de cobertura, los manejos que se realicen y las características de las zonas de estudios. Se enfatiza, además, en la recolecta adecuada de muestras, para los objetivos que se persiguen y lograr la mejor representación gráfica de la continuidad de las variables analizadas.

3.3 Predicciones y valoraciones espacio-temporales

Considerar la predicción como un insumo clave para el entendimiento de *trade-offs* asociados a los procesos de soporte, será elemental para los servicios ecosistémicos. Por ello, el diagnóstico realizado en esta investigación consolidó la captación de variabilidades espacio-temporales en escalas sub-campos y días de zafra; con ajuste de modelos predictivos.

3.3.1 Pronóstico de provisión azucarera

Los resultados descritos en los epígrafes anteriores evidenciaron que la provisión azucarera no presenta un comportamiento homogéneo para cada uno de los días de zafra; como tampoco es similar en todos los campos que generan el cultivo de la caña de azúcar, debido a diferentes zonas de manejo y necesidades específicas de elementos esenciales entre otros factores. Los diferentes estados y tendencias, tanto espaciales como temporales, sintetizados como variabilidades espacio-temporales y modelados por diferentes técnicas estadísticas, proveen conocimientos fundamentales para mejorar la toma de decisiones. En este trabajo, mediante el modelo ajustado a la serie de tiempo, se realiza el pronóstico de la provisión azucarera hasta el año 2025 (Fig. 3.11).

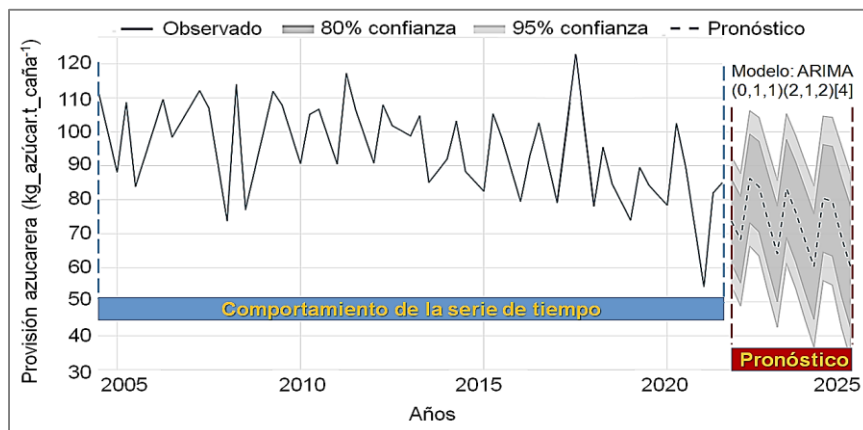


Figura 3.11 Pronóstico de la provisión azucarera según modelo propuesto

El pronóstico del modelo presenta una tendencia a la disminución, si persisten las dinámicas actuales; por lo que el proceso de toma de decisiones debe considerar la inclusión y análisis de los fenómenos relacionados con variabilidades espacio-temporales, potencial y pérdidas de azúcar. Según Cabrera *et al.* (2015), la aplicación del control estadístico de proceso (CEP) presenta gran efectividad en la disminución de los costos de producción; con la reducción de las pérdidas de azúcar. De acuerdo con Delgadillo-Ruiz *et al.* (2016), se mejora la toma de decisiones, si emplean de manera adecuada las técnicas de pronóstico en lugar de planear el futuro, sin el beneficio que aportan los modelos predictivos.

Los pronósticos son utilizados en el sistema socio-ecológico azucarero por diferentes autores, para crear escenarios futuros que pueden ser de utilidad en la toma de decisiones. En Hassan *et al.* (2019) se propone un modelo ARIMA (1, 2, 2) para el pronóstico de la producción de caña de azúcar en Bangladesh. Para Mwangi *et al.* (2017), un modelo ARIMA (2, 1, 2) (2, 0, 3) [4] se ajusta al rendimiento de caña de azúcar en Kenia y con el cual se realiza un pronóstico para el período de 2015 a 2024, además de destacar la utilidad de los modelos ARIMA estacionales. Asimismo, los resultados de Sanjeev *et al.* (2015) mostraron poca desviación entre el rendimiento agrícola predicho y real, con el uso de modelos ARIMA (0, 1, 1) y ARIMA (1, 1, 0), además, arribaron a pronósticos de corto plazo en tres distritos productores de Haryana, India. Estas literaturas se enfocan en los rendimientos agrícolas y no abordan el fenómeno en la etapa industrial que influye en la cantidad de azúcar que es el producto final del sistema socio-ecológico azucarero.

La provisión azucarera, acorde con el modelo causal establecido, variará en función del rendimiento potencial que posee el cultivo y de las pérdidas industriales (Fig. 3.12). Los límites de confianza y predicción se exponen para los valores medios de los predictores.

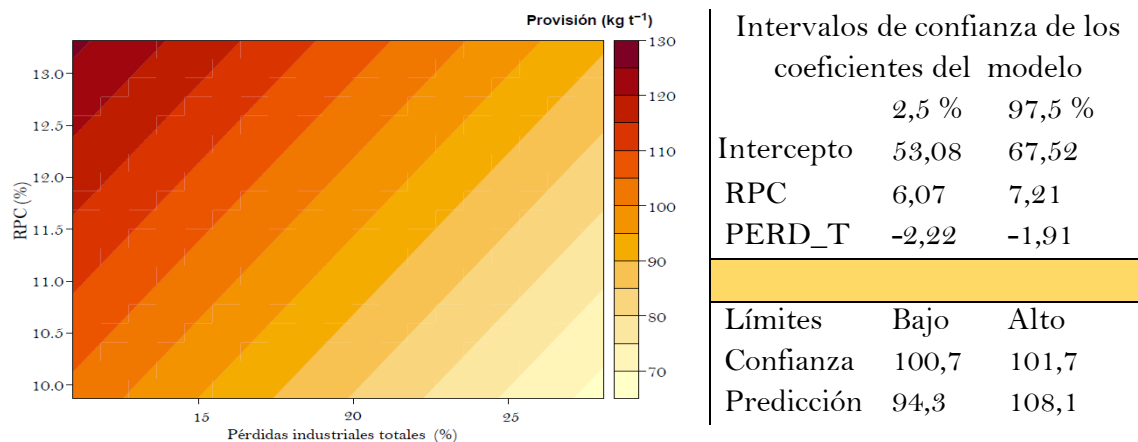


Figura 3.12 Gráfico del contorno del modelo de regresión lineal e intervalos de confianza

En Cala-Jústiz *et al.* (2020), se exponen la utilidad de la modelación econométrica para describir las relaciones de la producción de azúcar con las variables de eficiencia productiva. Al igual, el modelo de regresión lineal expuesto en esta Tesis puede servir a la comprensión de las relaciones que se presentan en el enfoque de servicios ecosistémicos de un contexto agroindustrial azucarero. La cantidad de azúcar por tonelada de caña molida, en el proceso industrial, se relaciona con las pérdidas en sacarosa, tanto físicas, químicas, como microbiológicas. Las primeras son pérdidas determinables como: Pol en bagazo, miel y cachaza, arrastres; la segunda es causada por la inversión de la sacarosa en glucosa y fructosa; mientras que las microbiológicas son pérdidas causadas por bacterias (Granja y Vidal, 2014).

3.3.2 Predicciones espaciales de la disponibilidad de nutrientes en el suelo

Las variabilidades espaciales en la disponibilidad de nutrientes son una expresión de cambio, en uno de los procesos de soporte de la provisión azucarera agroindustrial. El análisis espacial conlleva a interpolar a partir de los valores puntuales y delimitar, además, sitios específicos para cada categoría de suelo. En las figuras 3.13 y 3.14 se observan los resultados de la interpolación para la región evaluada.

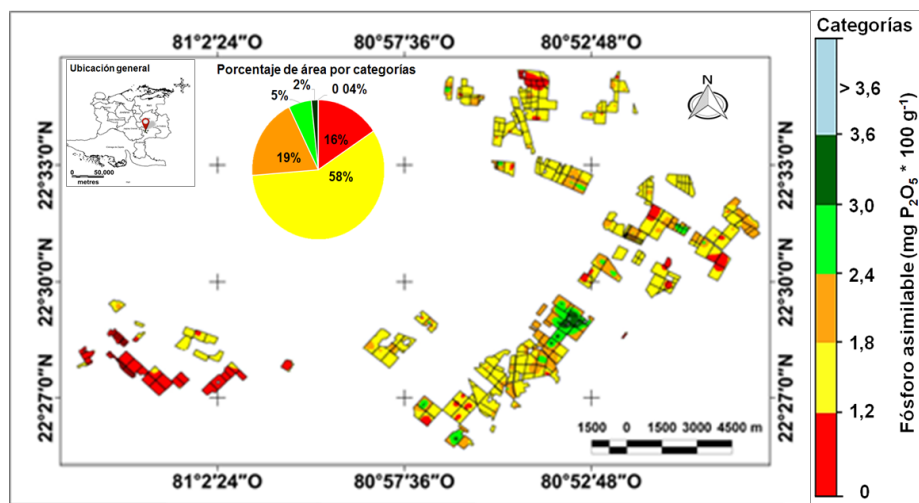


Figura 3.13 Mapa de la predicción espacial de fósforo asimilable

Como se observa en la figura 3.13, se obtiene un 16 % del área en categoría de bajo, 84 % en medio y 0,04 % en alto, según las categorías empleadas en el Servicio de Recomendación de Fertilizantes y Enmiendas (SERFE, 2014). Estas informaciones detalladas sobre la heterogeneidad de propiedades del suelo son requeridas para planificar un adecuado manejo de fertilizantes por sitios específicos para los cultivos agrícolas (Rosemary *et al.*, 2017).

En el caso del potasio asimilable del suelo (Fig. 3.14), se obtuvo un 30 % del área en categoría de muy bajo, 44 % en bajo, 24 % en medio y 2 % en alto. Según las categorías empleadas en el Servicio de Recomendación de Fertilizantes y Enmiendas (Pérez *et al.*, 2015; SERFE, 2014). También se observan necesidades variables, incluso dentro de los campos de caña de azúcar. Esto evidencia la necesidad de dosis variables dentro de estos, para lograr una mayor adaptación a las características del suelo. Su identificación permite asociar mejores manejos de fertilización, que son necesarios para la caña de azúcar, pues con la cosecha de este cultivo parte de los nutrientes son extraídos más allá de las fronteras de los campos (entre 0,4 y 0,6 kg de P_2O_5 y de 1,5 a 2,0 kg de K_2O , por toneladas de caña de azúcar cosechada) y sólo la fracción de los residuos de cosecha queda en el campo (De

León *et al.*, 2015). Por ello, se considera entre los principales factores, las formas asimilables de estos nutrientes en el suelo.

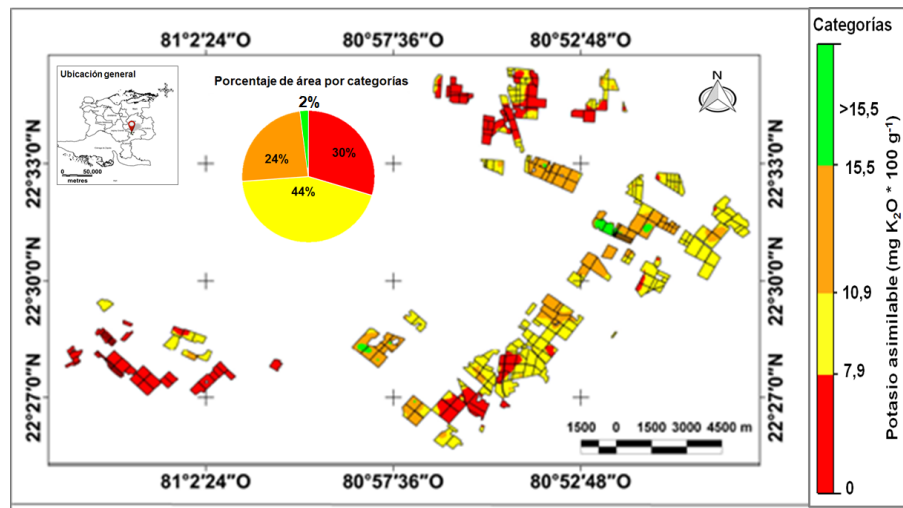


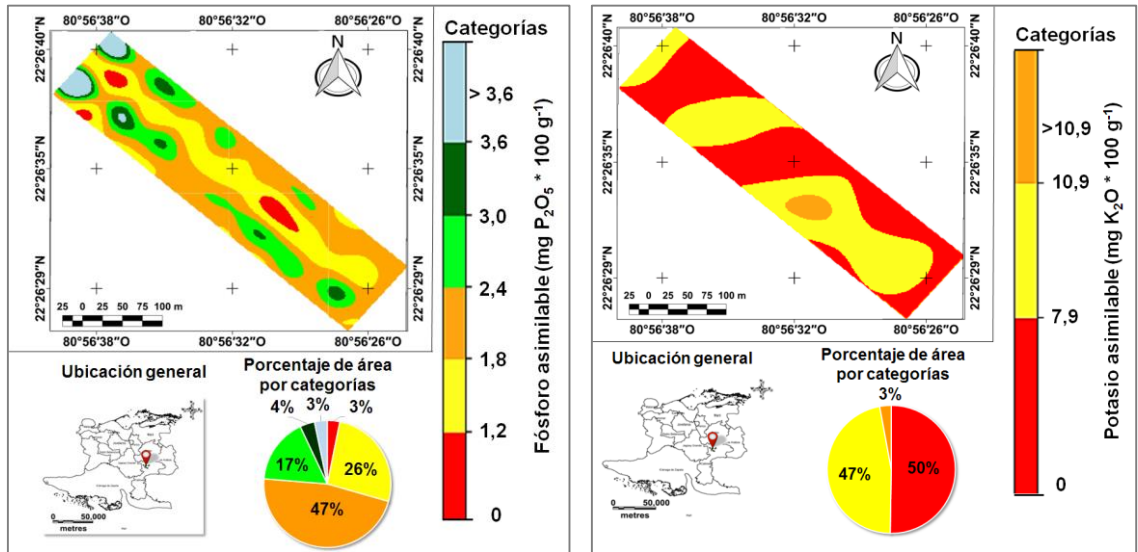
Figura 3.14 Mapa de la predicción espacial de potasio asimilable

Las predicciones evidencian la existencia de variabilidades dentro de los campos de cañas de azúcar. También los valores *nugget* encontrados en ambos semivariogramas (Fig. 3.9 a y b) encima del origen de coordenada, revelan la posible existencia de variabilidades por debajo de la escala muestreada (Gallardo, 2006).

Para el segundo caso de muestreo de suelo, también se realizó la predicción espacial de los elementos fósforo y potasio del suelo (Fig. 3.15 a y b). Para el caso del fósforo, el mayor porcentaje (47 %) se encontró en la categoría de medio (intervalo de 1,8 mg 100 g⁻¹ a 2,4 mg 100 g⁻¹). Las desviaciones estándar de la predicción aparecen en el Anexo 15. En la figura 3.15 (b) se observa la predicción del potasio asimilable del suelo en el área evaluada, donde el mayor porcentaje (50 %) se encontró en la categoría de muy bajo y el menor en la categoría de medio (3 %).

Asociado a la predicción del *kriging* está el análisis del error de predicción; esto se puede observar en los parámetros medidos en la validación cruzada (RMSE; MSE; R; MSDR), expuestos en los Anexos 13 y 14. En el Anexo 15 se observa también, como se incrementa

la desviación de la interpolación a medida que se aleja de las zonas de colecta de las muestras; mientras que en el Anexo 16 aparecen los residuos de cada punto georreferenciado.



Las interpolaciones aportan valiosas informaciones sobre las reservas de nutrientes del suelo, pero presentan la limitante de requerir un alto número de muestras para desarrollar el análisis geoestadístico (Oliver y Webster, 2015); por lo que es un desafío modelar las propiedades del suelo. Además, los valores para cada sitio específico son resultado de la compleja interacción entre factores ambientales y manejos antrópicos (Paterson *et al.*, 2018). Sin embargo, la identificación de sitios específicos dentro del campo de caña de azúcar, es un elemento básico para los manejos adaptados a las características variables del suelo y permite una mayor precisión de las recomendaciones de fertilizantes. Los resultados obtenidos (Fig. 3.13 a 3.15) para fósforo y potasio asimilables del suelo concuerda con Gallardo (2006), que expresa que estos serán distintos, si se muestrea a diferentes escalas, presentándose desiguales patrones espaciales, lo que demuestra que el sistema de muestreo de suelo y las áreas que representa, juega un papel fundamental en la

exactitud del semivariograma experimental (Kumar y Sinha, 2018; Oliver y Webster, 2015).

Las referencias mencionadas no exponen una solución para esta problemática, pero si dejan claro que mayor número de muestras (que sean representativas) permiten realizar una mejor caracterización del suelo y de las necesidades de nutrientes presentes, para mantener su fertilidad y la producción de cultivo; pero implica mayores gastos de diagnóstico.

El cultivo de la caña de azúcar depende de un adecuado balance nutricional para lograr su máxima expresión en biomasa y en cantidad de azúcar almacenada en los tallos, para su extracción en la etapa industrial. Los criterios para dosis óptimas en caña de azúcar se establecen en el SERFE (Pérez *et al.*, 2015). Sin embargo, la aplicación de dosis óptimas a cada sitio específico es el sendero de la agricultura de precisión, que permite hacerle frente a riesgos económicos y ambientales (Kitchen y Clay, 2019), pero es una tecnología poco extendida en el territorio cubano.

3.4 Perjuicios espacio-temporales de procesos de soporte y provisión azucarera

Dos importantes cuestiones para la sostenibilidad son: ¿Cómo los ecosistemas y los servicios que proveen cambiarán en el futuro? ¿Y cómo las decisiones humanas inciden en esos cambios? La respuesta a esas cuestiones requiere de la capacidad para predecir y pronosticar los cambios en los procesos ecológicos (Dietze *et al.*, 2018), a lo que se agregan los cambios en los procesos antrópicos y el computo de la brecha productiva entre potencial y real (García *et al.*, 2022).

3.4.1 Costo de las pérdidas industriales. Un modelo de predicción

El potencial azucarero es un máximo teórico de azúcar y es expresado como RPC, sin embargo, existe un distanciamiento entre potencial y real; su expresión, en términos

económicos, permite razonar la cantidad de beneficio dejado de percibir, además de visualizar un margen financiero que se puede tener, para invertir en acciones de mejoras y disminución de las pérdidas (García *et al.*, 2022).

En los datos recolectados se observan valores de aprovechamiento del RPC variables entre 80 % y 90 %, concentrados entre el primer y tercer cuartil, respectivamente. Lo expuesto refiere a la existencia de un conflicto donde, a medida que aumentan las pérdidas, se aleja la producción de azúcar real, del potencial que posee la caña de azúcar cosechada. De esta forma, las pérdidas en la industria implican un impacto negativo que afecta la provisión azucarera. Las determinaciones realizadas en esta investigación permiten representar en un modelo de polinomio (Fig. 3.16), el índice de perjuicios I_{p-DPRE} , mediante el cual se aprecia cómo las pérdidas pueden ocasionar, en términos económicos, un alejamiento del potencial azucarero de hasta 30 USD t^{-1} de caña molida a escala diaria, en función de los parámetros analizados.

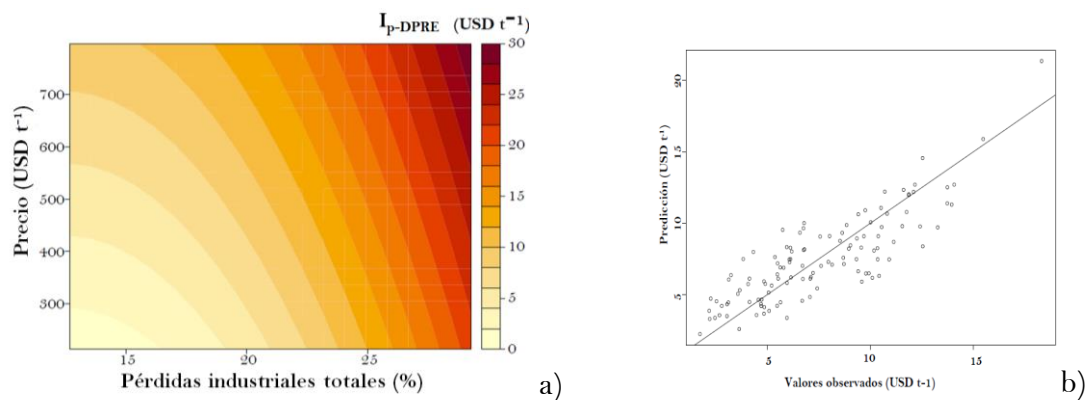


Figura 3.16 Modelo de efectos económicos de pérdidas totales industriales (a) y relación de valores de prueba con valores de predicción del modelo (b)

Mediante el análisis combinado de parámetros estadísticos calculados y métodos gráficos (Fig. 3.17), se considera que el modelo de polinomio expuesto cumple con los parámetros de diagnósticos, validación y es adecuado para predecir el índice I_{p-DPRE} en función de las pérdidas industriales totales y los precios del azúcar.

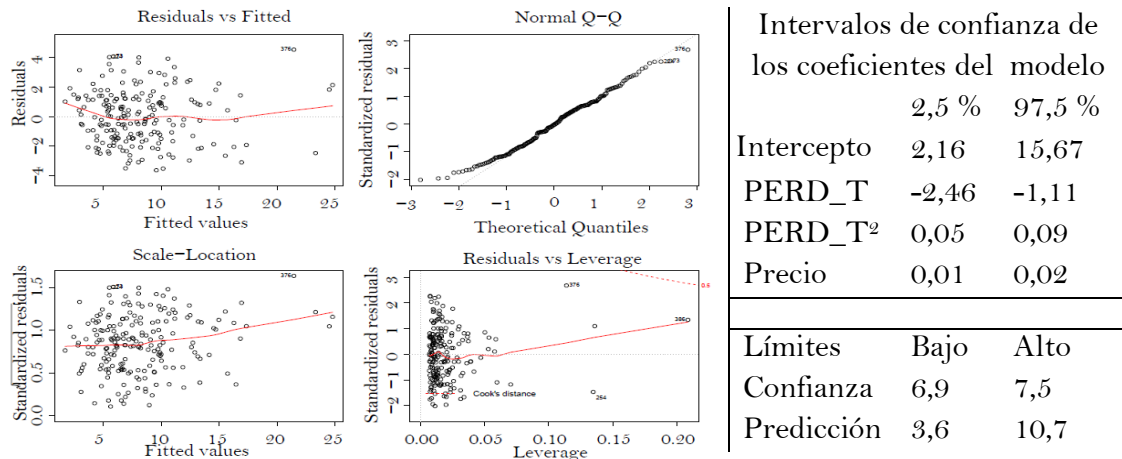


Figura 3.17 Validación del modelo de regresión de polinomio e intervalos de confianza

El modelo con la ecuación: $I_{p-DPRE} = 8,91 - 1,79(PERD_T) + 0,07(PERD_T)^2 + 0,01 \text{ Precio}$, es capaz de explicar el 82,09 % de la variabilidad observada en la variable I_{p-DPRE} (R^2 de 0,82). El test F muestra que es significativo ($p\text{-value} < 2,2 \cdot 10^{-16}$), con un error residual de 1,8 y 196 grados de libertad. Se cumplen los criterios estadísticos requeridos como la prueba de normalidad (prueba de *Lilliefors*: 0,05 y $p\text{-value}$: 0,2); residuos estandarizados (*Breusch-Pagan*: 7,7 y $p\text{-value}$: 0,053). La prueba de *Durbin-Watson* no encontró evidencias de autocorrelación, donde el estadístico d fue de 2,11 y el $p\text{-value}$ de 0,45. Además de lo expuesto, la figura 3.17 mostró cuatro gráficos que corroboran los resultados de los test estadísticos.

No es intención simplificar las complejidades del procesamiento de la caña de azúcar, sino exponer el predictor seleccionado y su relación con la existencia de variabilidades espacio-temporales en la provisión azucarera; su perjuicio en términos económicos variables y de esta forma aportar elementos de precisión para las valoraciones del sistema socio-ecológico azucarero. El modelo predice el comportamiento del indicador I_{p-DPRE} en términos monetarios. Esto puede ayudar a internalizar los impactos, en la valoración económica y de acuerdo con Bastian y Grunewald (2015) ser útil para mejorar la toma de decisiones.

Un análisis similar es realizado en pesos cubanos, lo que permite obtener un modelo en base a esta moneda (Anexo 17). Mientras que en el Anexo 18 se expone la relación entre la predicción en CUP y los valores obtenidos en USD multiplicados por un valor de cambio ($I_{p-DPRE} * 120$). De esta forma, ambos modelos pueden ser de utilidad para un análisis de perjuicio por distanciamiento entre provisión azucarera potencial y real en términos de CUP o USD.

3.4.2 Costos por dosis de fertilizantes en excesos y déficit

El manejo de los fertilizantes para la caña de azúcar se formula en base a la respuesta prevista del cultivo (Pérez *et al.*, 2015). La ausencia de tecnología de aplicaciones variables a escala sub-campo conlleva a que se aplique una misma dosis que puede ocasionar un exceso o déficit de fertilizante, según criterio seleccionado (tabla 3.7).

Tabla 3.7 Diferencias entre dosis variables y únicas de superfosfato triple para 5,6 ha evaluadas.

Categorías	Área (ha)	% del área	Necesidades por zonas (kg/ha)	Portador** a aplicar (kg)	Dosis única* (kg)	Diferencia ⁵ (kg)
Bajo	0,2	3,2	80	30,7	19,2	-11,5
Medio ¹	1,5	26,3	60	192,0	160	-32,0
Medio ²	2,6	46,9	50*	285,3	285,3	0
Medio ³	0,9	16,7	40	81,3	101,6	+20,3
Medio ⁴	0,2	3,7	30	13,6	22,8	+9,1
Alto	0,2	3,3	25	9,9	19,9	+9,9

* Dosis única de 50 kg ha⁻¹. ** Superfosfato triple (SPT). ^{1,2,3,4} Aunque se consideran como categoría de medio, las necesidades de fósforo van de 30 a 60 kg ha⁻¹: ⁵ El signo negativo en la columna “diferencia”, significa un déficit, mientras que el positivo refiere un exceso de fertilizante y solo donde el valor es cero, la dosis se adecúa a las necesidades del sitio específico.

La dosis única para el análisis del campo estudiado corresponde al área de mayor representatividad, en este caso de 2,63 ha y se encontró en el intervalo de 1,8 a

2,4 mg P₂O₅.100g⁻¹. Una fertilización basada en esta sola categoría significa que el resto de los sitios específicos presentes en el área, recibirían mayores o menores dosis que las necesitadas. Por ello, los diversos elementos del análisis de suelo necesitan ser transferidos a áreas geográficas, donde la disponibilidad de los datos, recursos y logísticas se consoliden en una base de sitios específicos para las valoraciones directas de servicios ecosistémicos (Macintosh *et al.*, 2019).

Los diferentes sitios específicos son variabilidades dentro de los campos de caña de azúcar y sin los manejos adecuados, se causan impactos en los procesos y servicios ecosistémicos (García y Cabrera, 2023). En otras palabras, los sitios específicos dentro de los campos de caña de azúcar requieren de dosis variables de fertilizantes (García *et al.*, 2017). La aplicación de una cuantía igual ocasiona un distanciamiento entre el manejo de fertilizante y los requerimientos de una agricultura de precisión, por conflictos entre estructuras antrópicas y sitios específicos del suelo. De esta forma se identifica un déficit (menor cantidad a aplicar que la necesitada) de 43,5 kg de SPT y un exceso (mayor cantidad a aplicar que la necesitada) de 39,3 kg de SPT, para el área evaluada de 5,6 ha. Solo 46,9 % del área recibiría la dosis adecuada acorde con la predicción geoestadística realizada.

Situación similar es presentada para el caso del potasio asimilable del suelo (tabla 3.8). En este caso el área más representativa corresponde con la categoría de muy bajo. Un manejo acorde con esta categoría ocasionaría al resto de las zonas identificadas (las categorías de bajo y medio encontradas en este campo) un exceso en la aplicación de fertilizante en sus áreas correspondientes. La aplicación del exceso de fertilizantes ascendería hasta 27, 27 kg de KCl_(s); donde solo el 50, 3 % del área recibiría la dosis adecuada acorde con el algoritmo del SERFE y el sitio específico identificado.

Tabla 3.8 Diferencias entre dosis única y variables de cloruro de potasio para 5,6 ha evaluadas

Categorías	Área (ha)	% del área	Necesidades ¹ por zonas (kg/ha)	Portador** a aplicar (kg)	Dosis única* (kg)	Diferencia (kg)
Muy bajo	2,8	50,3	110	516,0	516,0	0
Bajo	2,6	46,8	105	459,1	480,9	+21,9
Medio	0,2	2,9	90	24,4	29,8	+5,4

* Dosis única de 110 kg ha⁻¹. ** Cloruro de potasio (KCl_(s)). ¹Las necesidades de esta tabla son para el rendimiento de 69 t ha⁻¹. El signo positivo en la columna “diferencia”, refiere un exceso en la fertilización y el cero, es donde la dosis se ajusta al sitio específico.

Un conflicto importante que se presenta con el aumento de la exactitud y precisión en el manejo de nutrientes del suelo, se relaciona al gasto de recursos y la necesidad de mayores cantidades de muestras. Para el área evaluada en el epígrafe 3.3 se requería, según la cantidad de campos, de 278 muestras de suelo acorde con la metodología que se emplea en el Servicio de Recomendación de Fertilizantes y Enmiendas para cada campo de caña de azúcar (SERFE, 2014). Pero el estudio de mayor precisión se realiza con 671 muestras de suelo, lo que representa un 241,4 % por encima. Mientras que, para el caso de las 100 muestras, este porcentaje de incremento es aún mayor (333,3 % si se considera que una muestra compuesta se elabora de 30 sub-muestras). También se incorpora la acción de georreferenciación de cada punto de muestreo, para realizar el análisis espacial.

A partir de las predicciones geoestadísticas realizadas se construyeron los escenarios relacionados con hipotéticas dosis únicas según cada categoría encontrada en el polígono evaluado (Fig. 3.18). El valor de cada escenario representa un perjuicio por exceso o déficit de fertilizante, que podría ser solucionado por dosis variables acorde a necesidades de los sitios específicos. La figura 3.18 expone seis escenarios, donde cada barra representa el valor del perjuicio, si se aplicara a todo el campo evaluado la dosis de la categoría de ese

sitio específico; por ejemplo, una categoría de bajo en fósforo asimilable requiere una dosis de 80 kg ha⁻¹. La aplicación de esta única dosis ocasionaría un exceso, que es estimado por el procedimiento propuesto y ascendería hasta 225,1 USD ha⁻¹ (27 012 CUP ha⁻¹). Esto es hacia un extremo del gráfico, mientras que los valores medio, como se puede apreciar, incurrirían en exceso y déficit debido a la presencia de categorías de bajo y alto.




Figura 3.18 Escenarios relacionados a diferentes necesidades de fósforo

Situación similar es estimada para el caso de las variabilidades espaciales del potasio asimilable del suelo (Fig. 3.19).




Figura 3.19 Escenarios relacionados a diferentes necesidades de potasio

En la fertilización con potasio, también se considera el rendimiento esperado del cultivo (Pérez *et al.*, 2015); debido a esto se presentan los valores económicos para dos escenarios de rendimiento, junto a las categorías encontradas en el polígono evaluado. Los dos gráficos (Fig. 3.18 y 3.19) exponen como los manejos de nutrientes del suelo alejado de los criterios de sitios específicos, implican excesos o déficit de fertilizantes, lo cual es cuantificado en valores económicos por un índice de perjuicio espacial (I_{p-e}) en función de

las categorías del suelo. Así, los conflictos entre las estructuras antrópicas y la variabilidad de los nutrientes del suelo, genera perjuicios en este proceso de soporte de la provisión azucarera agroindustrial.

3.4.3 Valoración de perjuicios espacio-temporal del sistema socio-ecológico

La determinación de perjuicios requiere de un diagnóstico espacio-temporal, con diferentes predicciones que identifiquen los niveles de eficiencias en los procesos de soporte y contribuyan a mejores manejos adaptados. Una mejora es la aplicación variable de fertilizante, la cual no consiste solo en aplicar más o menos, sino en un arreglo apropiado de las dosis a los requerimientos de los sitios específicos. Aunque requiere de una inversión en equipos para estas prácticas; la ausencia de las mismas, acorde con los resultados mostrados, puede ocasionar perjuicios por exceso y déficit de fertilizantes fosfórico y potásico, con un valor de 437,9 USD a⁻¹ (52 547,4 CUP a⁻¹) por este concepto. Este valor es para un campo de 5,6 ha, donde solo una parte del área recibiría la dosis adecuada (46,9 % para el caso del fósforo y 50,3 % para el caso del potasio).

Sin embargo, las áreas fertilizadas cada año son más extensas. En la recomendación de un año estas se pueden extender a 612 campos agrícolas, en un área de 8074,6 ha del caso de estudio (SERFE, 2015), por lo que el valor de este perjuicio es aún mayor, acorde con los criterios que han sido encontrados. En cada año específico, los perjuicios son consecuencia de lo que acontece en las dimensiones espaciales y temporales. Una estimación de este valor a partir de los resultados expuestos y bajo la consideración de 4328,3 ha y 113 días de zafra, conduce a un perjuicio (PEET) de 1 207 783,4 USD a⁻¹ (144 934 009,1 CUP a⁻¹). El 40 % de ese valor corresponde a las variabilidades espaciales de los nutrientes del suelo, en cuyo caso se utilizan las áreas expuestas en la tabla 2.2 (Capítulo 2) y el factor de adaptación a partir de la figura 3.15 (a y b).

En los 113 días de zafra, se procesó 290 449,3 t de caña y se obtuvo una producción de 30 352,8 t de azúcar que representan un valor de 6 917 396, 3 USD a⁻¹ (830 087 556 CUP a⁻¹). El perjuicio (PEET) equivale a 17,5 % del valor de la producción mencionada y el índice (I_{p-vp}) expresa un perjuicio de 4,2 USD t⁻¹ (499 CUP t⁻¹) de caña molida; influido por los manejos para la disponibilidad de nutrientes del suelo y la eficiencia en la extracción de sacarosa que se le realiza a la caña de azúcar (Fig. 3.20).

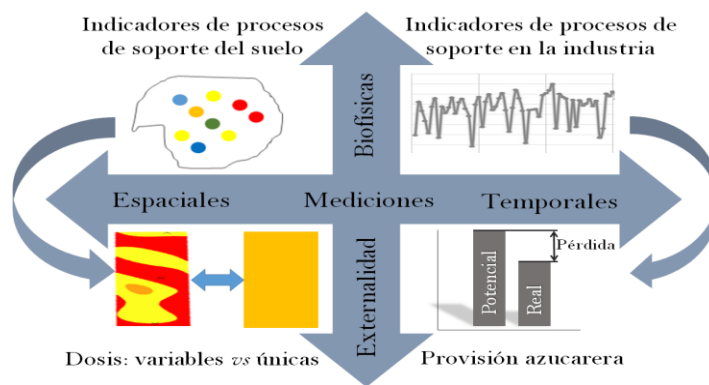


Figura 3.20 Valoraciones espacio-temporales de los procesos de soporte


La cuestión con la fertilización para los sitios específicos y el distanciamiento en la industria, entre la provisión azucarera agroindustrial potencial y real, no está solo en el costo económico; sino en la comprensión y necesidad de manejos adaptados eficientemente, para la sostenibilidad del sistema socio-ecológico azucarero y sus servicios ecosistémicos. Para esto último, son útiles los algoritmos de aprendizaje y su enriquecimiento con nuevos datos para lograr mayores conocimientos sobre las formas de manejos de los campos agrícolas y el procesamiento de la caña de azúcar. Lo que, según Ribas *et al.* (2016), puede contribuir con la comprensión de las variables tecnológicas de mayor peso, e influir en la planificación y optimización de los recursos técnicos, humanos, financieros y servir para alcanzar mejores resultados con la aplicación de diferentes herramientas gerenciales (Granja y Vidal, 2014). Así, el diagnóstico espacio-temporal, con

sus algoritmos de aprendizaje estadístico, modelos y predicciones espacio-temporales pueden derivar en:

- Establecimiento de rangos de trabajo (metas) bien definidas para las variables identificadas como importantes.
- Evaluación de procedimientos operacionales y eficiencias en el manejo de recursos, mediante las predicciones y pronósticos de indicadores de los procesos de soporte y la provisión azucarera agroindustrial.
- Determinación de las causas de conflictos e impactos, para aplicar las soluciones adaptadas para cada caso.
- Fomento de debates entre especialistas y el aprendizaje colectivo para valorar las mejores opciones y sus resultados.

La valoración del caso de estudio, mediante escenarios espaciales y temporales, en las etapas agrícola e industrial, abordó similitudes en las propiedades generales de distintas naturalezas del sistema socio-ecológico azucarero. De acuerdo con Betancourt y Valle (2016), existe correspondencia en los principios generales que gobiernan el comportamiento de elementos, intrínsecamente diferentes. Estos principios generales han sido, en esta investigación, una mayor variabilidad a menor escala de análisis y existencia de perjuicios relacionados a manejos en los procesos de soporte de la provisión azucarera agroindustrial.

Según la primera recolecta de muestras de suelo que abarcó 4086, 23 ha, existen variabilidades espaciales dentro de los campos estudiados, con posibilidades de encontrarlas por debajo de la escala muestreada. Además de esto, el análisis del campo muestreado en el 2019 denota permanencia de la variabilidad espacial para ambos elementos del suelo (Fig. 3.21).



a) Fósforo asimilable ($\text{mg P}_2\text{O}_5 \text{ } 100\text{g}^{-1}$) b) Potasio asimilable ($\text{mg K}_2\text{O } 100\text{g}^{-1}$)

Figura 3.21 Categorías de fósforo (a) y potasio (b) asimilable en diferentes años

Se observa, además de la existencia de variabilidad espacial, un incremento hacia valores más bajos, para ambos elementos estudiados. En paralelo, la categoría de alto del fósforo asimilable mostró un aumento. Estos efectos pueden estar relacionados con la ausencia de dosis variables, que afecta el adecuado balance de nutrientes de cada sitio específico.

El muestreo realizado en el año 2022, que abarcó otro sitio y condiciones diferentes (área con sistema de irrigación), también mostró una variabilidad espacial en el suelo, con diferentes categorías para los elementos evaluados de fósforo y potasio. Los resultados encontrados son evidencia de la variabilidad espacial a escala sub-campo y refuerzan la necesidad de considerar estos aspectos en la toma de decisiones para contribuir a la sostenibilidad del sistema socio-ecológico azucarero.

Es necesario destacar que la recomendación de fertilizantes, en especial la fosfórica, se ve influenciada por la acidez en el suelo (Pérez *et al.*, 2015), pues los niveles de pH inciden en la disponibilidad de nutrientes para los cultivos (Inamuddin *et al.*, 2021). En este escenario los resultados de las muestras de suelo en los polígonos estudiados, para los años 2016, 2019 y 2022 presentaron los coeficientes de variación de 21,54; 27,18 y 10,03 respectivamente. Aunque menores que los encontrados para los elementos fósforo y potasio en el suelo, aportan otra capa en los análisis de variabilidad (Fig. 3.22).




Figura 3.22 Representación de capas de análisis para una comprensión de sitios específicos

La presencia de la acidez también incidirá en criterios de variabilidad espacial y refuerza el argumento de esta tesis, sobre la necesidad de los manejos por sitios específicos. De acuerdo con Birgé *et al.* (2016), monitorear las variables del suelo ayuda a explorar los cambios que pueden afectar a los servicios ecosistémicos, así como el establecimiento y las recomendaciones de sitios específicos que mitiguen las limitantes con criterios sostenibles. La provisión azucarera agroindustrial requiere del análisis de cada campo agrícola con sus procesos de soporte y sus variabilidades espaciales, así como de la extracción azucarera y la influencia de cada día de zafra en el beneficio final. En este contexto, la inclusión de diversidad de valores puede ayudar a la identificación de conflictos, que serán la base fundamental para la construcción de escenarios (Rincón-Ruíz *et al.*, 2014). Por lo que el perfeccionamiento de la toma de decisiones, debe incluir el diagnóstico de diferentes indicadores de los procesos de soporte.

En el enfoque de servicios ecosistémicos, persiste una cuestión de beneficios y perjuicios. No solo es producir más azúcar, sino de cómo lograr ese objetivo con una mejor comprensión y adaptación a variabilidades espacio-temporales, en los procesos de soporte. Pues los niveles de eficiencias con que se manejan los recursos implican diferentes impactos económico-ambientales. Un fenómeno como las pérdidas industriales ocasiona un perjuicio, por la cantidad de azúcar no extraída, lo que afecta la relación costo-beneficio y origina una mayor demanda de recursos naturales para cumplir los compromisos pactados; lo que requeriría un incremento en la cantidad de caña de azúcar a procesar. Los perjuicios encontrados en el proceso de extracción azucarera, fundamentan el uso de la

inteligencia artificial, consistente con la visión de industria 4.0, que precisa de algoritmos de aprendizaje automático para analizar diferentes tipos de datos, encontrar relaciones, perfeccionar sistemas y adelantarse a problemas futuros (Lee, 2020). A la vez, los perjuicios por las variabilidades en la disponibilidad de nutrientes a escalas sub-campos, fundamentan la agricultura de precisión y el uso de tecnologías afines para reducir el impacto ambiental, aumentar la productividad y contribuir a la sostenibilidad del sistema socio-ecológico azucarero. Es de destacar que los perjuicios mencionados no son los únicos de este sistema; que puede impactar sobre la calidad del aire, el agua y el suelo (El Chami *et al.*, 2020).

Los resultados expuestos son útiles para evidenciar el fenómeno analizado. Donde, una mayor o menor eficiencia en los procesos de soporte estará en dependencia del rigor con que se trabaje, las dimensiones del área, el error permisible que se acepte y los recursos con que se cuente para diagnosticar y aplicar las recomendaciones específicas acorde con las variabilidades espacio-temporales; así como de las regulaciones y la conciencia que pueda existir para considerar a los procesos de soporte y los servicios ecosistémicos en la toma de decisiones (García y Cabrera, 2023). Es evidente que el análisis de mayor exactitud y precisión va aparejado a mayores costos de diagnóstico. Esta dificultad abre el camino a nuevas formas de colecta de información, con el uso de sensores proximales y remotos en el estudio de las variabilidades espacio-temporales (Shannon *et al.*, 2019), para el sistema socio-ecológico azucarero. De acuerdo con MIEA (2005), cada amenaza crea oportunidad para la innovación y la tecnología, que disminuyan los impactos negativos en los ecosistemas, además de significativas opciones de negocios para aquellos que son conscientes y estén preparados.

3.5 Conclusiones parciales del Capítulo 3

1. El diagnóstico espacio-temporal de los procesos de soporte es fundamental para los manejos de adaptación, la mitigación de perjuicios y el desarrollo de los servicios ecosistémicos, en el sistema socio-ecológico azucarero.
2. La selección del modelo ARIMA $(0, 1, 1) (2, 1, 2)$ [4], para datos de serie de tiempo, así como de la regresión lineal múltiple, son útiles para el análisis de relaciones causales y pronósticos de la provisión azucarera.
3. Se encontró que las pérdidas totales en la industria establecen un distanciamiento entre el potencial que posee este cultivo y la producción de azúcar, lo que puede alcanzar un valor para los días de zafra de 30 USD t^{-1} (3600 CUP t^{-1}) de caña molida, en función de diferentes precios del azúcar.
4. El análisis espacial evidenció la existencia de sitios específicos dentro de las estructuras de campos establecidas, incluso para un área de 5,6 ha. Esto implica la existencia de perjuicios por excesos y déficit de fertilizantes, que oscilaron entre de 109,7 a 225,1 USD ha^{-1} (13 164 a 27 012 CUP ha^{-1}) en el caso del fosforo, mientras que para el potasio estas se encontraron entre 26,7 y 146,9 USD ha^{-1} (3204 a 17 628 CUP ha^{-1})
5. Una estimación de los perjuicios, a partir de los resultados expuestos y bajo la consideración de 4328,3 ha y 113 días de zafra, permitió arribar a un valor de 1 207 783,4 USD a^{-1} (144 934 009,1 CUP a^{-1}), donde 40 % corresponde a las variabilidades espaciales de los nutrientes del suelo y el resto a causas de las pérdidas industriales.

CONCLUSIONES GENERALES

Como resultado final del trabajo desarrollado, se ha podido arribar a las conclusiones siguientes:

1. Los modelos predictivos permiten un diagnóstico espacio-temporal de procesos de soporte y provisión azucarera agroindustrial, con el pronóstico de comportamientos futuros y la identificación de sitios específicos para manejos de adaptación en el sistema socio-ecológico azucarero.
2. La relación entre valores biofísicos y económicos permitieron el ajuste de un modelo de polinomio y la predicción de un perjuicio que puede alcanzar un valor de 30 USD t^{-1} (3600 CUP t^{-1}) de caña molida, según los parámetros considerados de pérdidas industriales y precios del azúcar.
3. La falta de manejos adaptados a la disponibilidad de nutrientes del suelo a escala sub-campo puede ocasionar exceso y déficit de fertilizantes, con valores máximos de perjuicios, según los parámetros de este trabajo, de 225,1 y 146,9 USD ha^{-1} (27 012 y 17 628 CUP ha^{-1}), para los casos de fósforo y potasio, respectivamente.
4. Los perjuicios relacionados a los procesos de soporte del sistema socio-ecológico azucarero son recogidos en un índice I_{p-vp} de 4,2 USD t^{-1} (499 CUP t^{-1}) de caña molida. Este valor es afectado por los manejos de fertilizantes y su adaptación a la disponibilidad de nutrientes del suelo, así como por la eficiencia en la extracción de sacarosa del proceso industrial.
5. Los resultados evidencian que la disminución de la escala de análisis espacio-temporal, en procesos de soporte, aporta criterios de precisión y exactitud para los manejos de adaptación que pueden contribuir a la sostenibilidad del sistema socio-ecológico azucarero.

RECOMENDACIONES

Basadas en las conclusiones obtenidas y para la extensión futura del presente trabajo, se realizan las siguientes recomendaciones:

1. Realizar la divulgación de los resultados obtenidos, así como la preparación de acciones de capacitación y formación dirigida a especialistas y decisores del sector azucarero, sobre el enfoque ecosistémico y el uso de modelos predictivos.
2. Utilizar el enfoque ecosistémico en las valoraciones, toma de decisiones y manejos de adaptación del programa de agricultura de precisión que se desarrolla en la agroindustria azucarera de “Jesús Rabí”.
3. Desarrollar un sistema automático para los ajustes de modelos predictivos que contribuya con el diagnóstico de los procesos de soporte y la provisión azucarera agroindustrial.

REFERENCIAS BIBLIOGRÁFICAS

- Adetunji, C.O., & Osarenotor, O. (2021). Essential Soil Functions for Enhanced Agricultural Productivity and Food Production. In: Inamuddin *et al.* (Eds.), *Applied Soil Chemistry* (pp. 215–234). Hoboken (USA): John Wiley & Sons. doi:10.1002/9781119711520
- Adhikari, K., & Hartemink, A. (2016). Linking soils to ecosystem services. A global review”. *Geoderma*, 262, 101–111. <http://dx.doi.org/10.1016/j.geoderma.2015.08.009>.
- Ahmad, A.F., & Hussain, A. (2020). Precision Farming for Resource Use Efficiency. In: S. Kumar *et al.* (Eds.). *Resources Use Efficiency in Agriculture* (pp. 109-136). Singapore: Springer. https://doi.org/10.1007/978-981-15-6953-1_4.
- Ahumada-Tello, E., Castañón-Puga, M., Gaxiola-Pacheco, C., & Evans, R.D. (2019). Applied Decision Making in Design Innovation Management. In: M. A. Sanchez *et al.* (Eds.), *Applied Decision-Making*, Studies in Systems, Decision and Control 209, Cham (Switzerland): Springer. https://doi.org/10.1007/978-3-030-17985-4_5
- Akima, H., & Gebhardt, A. (2016). akima: Interpolation of Irregularly and Regularly Spaced Data. R package version 0.6-2. <https://CRAN.R-project.org/package=akima>
- Alonso, A. (2021). La predicción de series temporales mediante el modelo de regresión. *Anuario Jurídico y Económico Escurialense*, LIV, 261-280. https://www.google.com/url?sa=t&source=web&rct=j&url=https://dialnet.unirioja.es/descarga/articulo/8162273.pdf&ved=2ahUKEwipupDlrer5AhUys4QIHZMH_BNEQFnoECA4QAQ&usg=AOvVaw2mFZIC_2KkjQz1u-4MV8nA

- Anderson, D., Sweeney, D., & Williams, T. (2012). Análisis de series de tiempo y elaboración de pronósticos. En: Anderson *et al.* (Eds), *Estadística para negocios y economía*. 11ª edición. (pp.784-854). D.F (México): Cengage Learning. [https://www.academia.edu/35861890/Análisis de series de tiempo y elaboración de pronósticos](https://www.academia.edu/35861890/Análisis_de_series_de_tiempo_y_elaboración_de_pronósticos)
- Andrade V.A. y Flores, P. (2018). Comparativa entre classification trees, random forest y gradient boosting, en la predicción de la satisfacción laboral en Ecuador. *Ciencia Digital*, 2, (4.1), 42-54. <https://doi.org/10.33262/cienciadigital.v2i4.1.189>
- Annabi, M., Raclot, D., Bahri, H., Bailly, J., Gomez, C., & Bissonnais, Y. (2017). Spatial variability of soil aggregate stability at the scale of an agricultural region in Tunisia. *Catena*, 153, 157–167. <http://dx.doi.org/10.1016/j.catena.2017.02.010>
- Auguie, B. (2017). gridExtra: Miscellaneous Functions for "Grid" Graphics. R package version 2.3. <https://CRAN.R-project.org/package=gridExtra>
- Avriel-Avn, M., & Dick, J. (2019). Differing perceptions of socio-ecological systems: Insights for future transdisciplinary research. In: Bohan & Dumbrell (Eds) *Advances in Ecological Research*, (pp. 153-190). London (United Kingdom): Elsevier. <https://doi.org/10.1016/bs.aecr.2019.03.001>
- AZCUBA. (2020). Evaluación diaria para dirigir económicamente. Informe No. 096. Empresa Azucarera Provincial. Matanzas, Cuba.
- Bastian, O. (2015). Governance in Nature Conservation. In: Grunewald, K., & Bastian, O. (Eds.), *Ecosystem Services – Concept, Methods and Case Studies* (pp. 172-185). Berlin (Germany): Springer. doi:10.1007/978-3-662-44143-5_5

- Bastian, O., & Grunewald, K. (2015). Properties, Potentials and Services of Ecosystems".
 In: Grunewald, K., & Bastian, O. (Eds), *Ecosystem Services – Concept, Methods and Case Studies* (pp. 36-45). Berlin (Germany): Springer. doi:10.1007/978-3-662-44143-5_3
- Bastian, O., Grunewald, K., & Syrbe, R.-U. (2015). Classification of ES. In: Grunewald, K., & Bastian, O. (Eds), *Ecosystem Services – Concept, Methods and Case Studies* (pp. 46-53). Berlin (Germany): Springer. doi:10.1007/978-3-662-44143-5_3
- Bednářová, Z., Kalina, J., Hájek, O., Sážka, M., & Komprdová, K. (2016). Spatial distribution and risk assessment of metals in agricultural soils. *Geoderma*, 284, 113–121. <http://dx.doi.org/10.1016/j.geoderma.2016.08.021>.
- Beguín, J., Fuglstad, G., Mansuy, N., & Paré, D. (2017). Predicting soil properties in the Canadian boreal forest with limited data: Comparison of spatial and non-spatial statistical approaches. *Geoderma*, 306, 195–205. <http://dx.doi.org/10.1016/j.geoderma.2017.06.016>
- Betancourt, O. y Valle, J. (2016). Teoría general de los sistemas. En: Betancourt *et al.*, (Eds), *Enfoques ecosistémicos en salud y ambiente* (pp. 65-81). Quito (Ecuador): Ediciones Abya-Yala.
- Bhunja, G., Kumar, P., & Chattopadhyay, R. (2018). Assessment of spatial variability of soil properties using geostatistical approach of lateritic soil (West Bengal, India). *Annals of Agrarian Science*, 16, 436–443. <https://doi.org/10.1016/j.aasci.2018.06.003>
- Birgé, H.E., Bevans, R.A., Allen, C.R., Angeler, D.G., Baer, S.G., & Wall, D.H. (2016). Adaptive management for soil ecosystem services. *J. Environ. Manag.* 183, 371-378. <http://dx.doi.org/10.1016/j.jenvman.2016.06.024>
- Bivand, R., Pebesma, E., & Gómez-Rubio, V. (2008). *Applied Spatial Data Analysis with R*. New York, (USA): Springer. doi:10.1007/978-0-387-78171-6.

- Bivand, R., Pebesma, E., & Gomez-Rubio, V. (2013). sp: Classes and methods for spatial. R package version 1.3-1. <https://CRAN.R-project.org/package=sp>
- Bivand, R., & Lewin-Koh, N. (2017). maptools: Tools for Reading and Handling Spatial Objects. R package version 0.9-2. <https://CRAN.R-project.org/package=maptools>
- Bivand, R., Keitt, T., & Rowlingson, B. (2018). rgdal: Bindings for the 'Geospatial' Data Abstraction Library. R package version 1.3-3. <https://CRAN.R-project.org/package=rgdal>
- Bivand, R., & Rundel, C. (2018). rgeos: Interface to Geometry Engine - Open Source ('GEOS'). R package version 0.3-28. <https://CRAN.R-project.org/package=rgeos>
- Bocca, F.F., Rodrigues, L.H.A., & Arraes, N.A.M. (2015). When do I want to know and why? Different demands on sugarcane yield predictions. *Agricultural Systems*, 135, 48–56. <http://dx.doi.org/10.1016/j.agsy.2014.11.008>
- Bogunovic, I., Mesic, M., Zgorelec, Z., Jurisic, A., & Bilandzija, D. (2014). Spatial variation of soil nutrients on sandy-loam soil. *Soil & Tillage Research*, 144, 174–183. <http://dx.doi.org/10.1016/j.still.2014.07.020>.
- Bogunovic, I., Trevisani, S., Seput, M., Juzbasic, D., & Durdevic, B. (2017). Short-range and regional spatial variability of soil chemical properties in an agro-ecosystem in eastern Croatia. *Catena*, 154, 50–62. DOI: <http://dx.doi.org/10.1016/j.catena.2017.02.018>
- Bruel, A., Kronenberg, J., Troussier, N., & Guillaume, B. (2018). Linking Industrial Ecology and Ecological Economics. *Journal of Industrial Ecology*, 1-10. doi:10.1111/jiec.12745
- Bruulsema, T. (2018). Managing nutrients to mitigate soil pollution. *Environmental Pollution*, 243, 1602-1605. <https://doi.org/10.1016/j.envpol.2018.09.132>.

- Bull, J.W, Jobstvogt N., Böhnke-Henrichs, A., Mascarenhas, A., Sitas, N., Baulcomb, C., Lambini, C.K., Rawlins, M., Baral, H., Zähringer, J., Carter-Silk, E., Balzan, M.V., Kenterm, J.O., Häyhä, T., Petz, K., & Koss, R. (2016). Strengths, Weaknesses, Opportunities and Threats: A SWOT analysis of the ecosystem services framework. *Ecosystem Services*, 7, 99–111. <http://dx.doi.org/10.1016/j.ecoser.2015.11.012>
- Bünemann, E. k., Bongiorno, G., Bai, Z., Creamer, R.E., Deyn, G., Goedeb, R., Geissen, V., Kuyper, T., Paul Mäder, P., Mirjam Pulleman, M., Wijnand Sukkel, W., Groenigen, J., & Brussaard, L. (2018). Soil quality – A critical review. *Soil Biology and Biochemistry*, 120, 105–125. <https://doi.org/10.1016/j.soilbio.2018.01.030>
- Burkhard, B., & Müller, F. (2015). Indicators and Quantification Approaches. IN: Grunewald, K. y Bastian, O. (Eds.), *Ecosystem Services – Concept, Methods and Case Studies* (pp. 76-84). Berlin (Germany): Springer. doi:10.1007/978-3-662-44143-5
- Burkhard, B., & Maes, J. (Eds.) (2017). *Mapping Ecosystem Services*. Sofia (Bulgaria): Pensoft Publishers.
- Cabrera, A., de la Cruz, O., Gómez, B., & Rodríguez, R. (2015). Integración de métodos estadísticos y económicos para la gestión en el proceso industrial cubano del azúcar de caña. Caso de estudio. *Rev. Téc. Ing. Univ. Zulia*, 38 (3), 209 – 215. <http://ve.scielo.org/pdf/rtfiuz/v38n3/art03.pdf>
- Cabrera–Milanés, A. y Rodríguez–Betancourt, R. (2015). Perfeccionamiento de estimados fabriles en la Unidad Empresarial de Base central azucarero “Paquito Rosales”, de la provincia Santiago de Cuba. *Anuario Facultad de Ciencias Económicas y Empresariales*, Número Especial. 73-84. <https://revistas.uo.edu.cu/index.php/aeco/article/viewFile/545/521>

- Cahn, M.D., Hummel, J.W., & Brouer, B.H. (1994). Spatial analysis of fertility for site-specific crop management. *Soil Sci Soc Am J*, 58, 1240–1248.
- Cai, L., Wang, Q., Wen, H., Luo, J., & Wang, S. (2019). Heavy metals in agricultural soils from a typical township in Guangdong Province, China: Occurrences and spatial distribution. *Ecotoxicology and Environmental Safety*, 168, 184–191.
<https://doi.org/10.1016/j.ecoenv.2018.10.092>
- Cala-Jústiz, Y., Pacheco-Feria, U. y Sánchez-Jiménez, M. (2020). Análisis de indicadores de eficiencia productiva y perspectivas de la industria azucarera en Santiago de Cuba. *AFCEE*, Número especial.
<https://www.google.com/url?esrc=s&q=&rct=j&sa=U&url=https://anuarioeco.uo.edu.cu/index.php/aeco/article/view/5144/4617&ved=2ahUKEwiMl93V3fvxAhXqRTABHR9qBhYQFjADegQICBAB&usg=AOvVaw0TQglq602lyZw1ZZAYgaFZ>
- Carrasquilla-Batista, A., Chacón-Rodríguez, A., Núñez-Montero, K., Gómez-Espinoza, O., Valverde, J. y Guerrero-Barrantes, M. (2016). Regresión lineal simple y múltiple: aplicación en la predicción de variables naturales relacionadas con el crecimiento microalgal. *Tecnología en Marcha*, 29, 33-45. doi:10.18845/tm.v29i8.2983
- Castillo-Eguskiza, N., Schmitz, M.F., Onaindia, M., & Rescia, A.J. (2019). Linking Biophysical and Economic Assessments of Ecosystem Services for a Social–Ecological Approach to Conservation Planning: Application in a Biosphere Reserve (Biscay, Spain). *Sustainability*, 11, 3092. doi:10.3390/su11113092
- Castro, M., García, D. y Jiménez, A. (2017). Comparación de técnicas de interpolación espacial de propiedades del suelo en el piedemonte llanero colombiano. *Revista Tecnura*, 21(53), 78-95. doi:10.14483/22487638.11658

- Charlotte, E.L., Neiva, N.B. y Moreira, C. (2014). Creación de mapas de manejo con datos espaciales”. En: Chartuni, E., Magdalena, C. (Eds.). *Manual de agricultura de precisión* (pp. 76-85). Montevideo (Uruguay): Instituto Interamericano de Cooperación para la Agricultura, PROCISUR. <http://www.gisandbeers.com/RRSS/Publicaciones/Manual-Agricultura-Precision.pdf>.
- Chiang, J., González, V., Reyes, Y. y Miño, J. (2018). Influencia de las variedades de caña sobre la eficiencia industrial en la fábrica “14 de julio de Cienfuegos. *Centro Azúcar*, 45, 41-49. http://centroazucar.uclv.edu.cu/index.php/centro_azucar/article/download/52/45/73
- Christin, S., Hervet, E., & Lecomte, N. (2019). Applications for deep learning in ecology. *Methods Ecol Evol*, 10, 1632–1644. doi: 10.1111/2041-210X.13256
- Contreras-Juárez, A., Atziry, C., Martínez, J. y Sánchez, D. (2016). Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos. *Estudios Gerenciales*, 32, 387–396. <https://doi.org/10.1016/j.estger.2016.11.002>
- Cord, A., Schwarz, N., Seppelt, R., Volk, M., & Schröter, M. (2019). Introduction to Part III: Trade-Offs and Synergies Among Ecosystem Services. In: Schröter *et al.* (Eds) *Atlas of Ecosystem Services* (pp. 245- 248). Gewerbestrasse (Switzerland): Springer. <https://doi.org/10.1007/978-3-319-96229-0> .
- Costanza, R., d’Arge, R., de Groot, RS., Farber, S., Grasso, M., Hannon, B., Limburg, K., Naeem, S., O’Neill, R., Paruelo, J., Raskin, RG., Sutton, P., & van den Belt, M. (1997). The Value of the World’s Ecosystem Services and Natural Capital. *Nature*, 387, 253-260. http://www.esd.ornl.gov/benefits_conference/nature_paper.pdf

- Crespin, S., & Simonetti, J. (2016). Loss of ecosystem services and the decapitalization of nature in El Salvador. *Ecosystem Services*, 17, 5–13. <http://dx.doi.org/10.1016/j.ecoser.2015.10.020>
- Dai, W., Li, Y., Fu, W., Jiang, P., Zhao, K., Li, Y., & Penttinen, P. (2018). Spatial variability of soil nutrients in forest areas: a case study from subtropical China. *J. Plant Nutr. Soil Sci*, 000, 1–9. doi:10.1002/jpln.201800134
- De Groot, R., Braat, L., Costanza, R. (2017). A short history of the ecosystem services concept. In: Burkhard, & Maes (Eds.) *Mapping Ecosystem Services* (pp. 31-34). Sofia (Bulgaria): Pensoft Publishers.
- De León, M., Pérez, H., & Villegas, R. (2015). Nutrición y Fertilización. En: Pérez *et al.* (Eds) *Manejo Sostenible de Tierras en la Producción de Caña de Azúcar* (pp. 25-78). Segunda edición. Machala (Ecuador): Ediciones Universidad Técnica de Machala. <http://repositorio.utmachala.edu.ec/bitstream/48000/6649/1/16%20MANEJO%20SOSTENIBLE%20DE%20LA%20TIERRA%20EN%20LA%20PRODUCCION%20DE%20CA%20C%2091A%20DE%20AZUCAR%20VOL%20II.pdf>.
- Delgadillo-Ruiz, O., Ramírez-Moreno, P., Leos-Rodríguez, J., Salas, J. y Valdez-Cepeda, R. (2016). Pronósticos y series de tiempo de rendimientos de granos básicos en México. *Acta Universitaria*, 26 (3). doi:10.15174/au.2016.882
- Dietze, M., Fox, A., Beck-Johnson, L., Betancourt, Hooten, B., Jarnevich, S., Keitt, H., Kenney, A., Laney, M., Larsen, G., Loescher, W., Lunch, K., Pijanowski, C., Randerson, T., Read, K., Tredennick, T., Vargas, R., Weathers, C., & White, E. (2018). Iterative near-term ecological forecasting: Needs, opportunities, and challenges. *Proceedings of the National Academy of Sciences*. 115 (7), 1424-1432. doi:10.1073/pnas.1710231115

- Dominati, E., Mackay, A., Greenb, S., & Pattersonc, M. (2014). A soil change-based methodology for the quantification and valuation of ecosystem services from agro-ecosystems: A case study of pastoral agriculture in New Zealand. *Ecological Economics*, 100, 119–129. <http://dx.doi.org/10.1016/j.ecolecon.2014.02.008>
- Eastwood, A., Brooker, R., Irvine, R., Artz, R., Norton, L., Bullock, J., Ross, L., Fieldin, D., Ramsay, S., Roberts, J., Anderson, W., Dugan, D., Cooksley, S., & Pakeman, R. (2016). Does nature conservation enhance ecosystem services delivery? *Ecosystem Services*, 17, 152–162. <http://dx.doi.org/10.1016/j.ecoser.2015.12.001>.
- Elliott, M. y O'Higgins, T. G. (2020). From DPSIR the DAPSI (W) R (M) Emerges. . . a Butterfly – ‘protecting the natural stuff and delivering the human stuff’. In: O'Higgins, G., *et al.* (Eds.). *Ecosystem-Based Management, Ecosystem Services and Aquatic Biodiversity* (pp. 61-86). Gewerbestrasse (Switzerland): Springer. https://doi.org/10.1007/978-3-030-45843-0_4
- El Chami, D., Daccache, A., & Moujabber, M. (2020). What are the impacts of sugarcane production on ecosystem services and human well-being? A review, *Annals of Agricultural Sciences*, 65 (2), 188-199. <https://doi.org/10.1016/j.aogas.2020.10.001>
- Elsasser, P., & Englert, H. (2015). Economic Benefit Valuation of the Influence of a Forest Conversion Programme on Ecosystem Services in the Northeastern Lowlands of Germany. In: Grunewald, K. y Bastian, O. (Eds.), *Ecosystem Services – Concept, Methods and Case Studies*. Berlin (Germany): Springer, 208-215. doi:10.1007/978-3-662-44143-5
- Fernández, D.E. y Ribes, M.D. (2014). Uso de la geoestadística y los sistemas de información geográfica en agricultura. En: Chartuni, E. y Magdalena, C. (Eds.). *Manual de agricultura de precisión* (pp. 86-62). Montevideo (Uruguay): Instituto

- Interamericano de Cooperación para la Agricultura, PROCISUR.
<http://www.gisandbeers.com/RRSS/Publicaciones/Manual-Agricultura-Precision.pdf>.
- Ferraro D., Piñeiro G., Laterra P., Nogués A. y de Prada J. (2010). Aproximaciones y herramientas para la Evaluación de servicios ecosistémicos. En: Laterra, P, Esteban, G, Paruelo, J. (Eds). *Valoración de Servicios ecosistémicos* (pp. 673-687). Buenos Aires (Argentina): Instituto Nacional de Tecnología Agropecuaria.
<http://www.iai.int/files/LaterraJobbagyParueloValorEcosyst.pdf>
- Fisher, B., Bateman, I., & Turner, R.K. (2011). Valuing Ecosystem Services: Benefits, Values, Space and Time. *Ecosystem Services Economics*, 3, 1-11. http://www.bioeconetwork.org/pages/UNEP_publications/03%20Valuing%20Ecosystem%20Services.pdf
- Fox, J., & Weisberg, S. (2011). car: Companion to Applied Regression. Second Edition. R package version 3.0-2. <https://CRAN.R-project.org/package=car>
- Fu, W., Tunney, H., & Zhang, C. (2010). Spatial variation of soil nutrients in a dairy farm and its implications for site-specific fertilizer application. *Soil and Tillage Research*, 106, 185–193. doi:10.1016/j.still.2009.12.001.
- Gallardo, A. (2006). Geostadística. *Ecosistemas*, 15 (3), 48-58.
http://www.google.com/cu/url?sa=t&rct=j&q=&esrc=s&source=web&cd=7&cad=rja&uact=8&sqi=2&ved=0CDAQFjAGahUKEwj89I7y1IrIAhUJWx4KHTwEAMA&url=http%3A%2F%2Fwww.revistaecosistemas.net%2Findex.php%2Fecosistemas%2Farticle%2Fdownload%2F161%2F158&usq=AFQjCNEKYP8f_THdP7nqMzjtY7Ou6W07w&bvm=bv.103073922,d.dmo
- Ganesapillai, M., Simha, P., Sudhir, S., & Sekhare, D. (2016). Low-grade rock phosphate enriched human urine as novel fertilizer for sustaining and improving agricultural

- productivity of *Cicer arietinum*. *Sustainable Production and Consumption*, 6, 62-66.
<http://dx.doi.org/10.1016/j.spc.2016.01.005>
- Gao, X.S., Xiao, Y., Deng, L.J., Li, Q.Q., Wang, C.Q., Li, B., Deng, O.P., & Zeng, M., (2019). Spatial variability of soil total nitrogen, phosphorus and potassium in Renshou County of Sichuan Basin, China. *J Integr Agric*, 18, 279–289. doi: 10.1016/S2095-3119(18)62069-6
- García, Y. y Hernández, D. (2015). El proceso agroindustrial de la caña de azúcar y los bienes y servicios ecosistémicos. Artículo presentado en el 10^{mo} Congreso Internacional de Educación Superior. Matanzas (Cuba).
- García, Y., Sánchez, Y., Fernández, E., Orozco, M. y García, V. (2017). Evaluación de la variabilidad espacial del suelo y su incidencia en las recomendaciones de fertilizantes en caña de azúcar. Artículo presentado en el Congreso Internacional Sobre Azúcar y Derivados de la Caña. La Habana (Cuba).
- García, Y., Sánchez, Y., Orozco, M., Fernández, A. y Madan, L. (2019). Manejo de nutriente para caña de azúcar y su relación con los servicios ecosistémicos. Artículo presentado en el Congreso Internacional Sobre Azúcar y Derivados de la Caña. La Habana (Cuba).
- García, Y., Sánchez, Y., Orozco, M. B. y Fernández, E. A. (2020). Variabilidad espacial del fósforo asimilable en un suelo ferralsol cultivado con caña de azúcar. *Revista Científica Agroecosistemas*, 8(3), 77-82.
- García, Y. y Orozco, M. (2021). Análisis geoestadístico como base para contribuir al manejo sostenible del agrosistema azucarero. *Ingeniería Industrial*, 42(2), 1-14.

- García, Y., González, L.Y. y Cabrera, J.A. (2022). Aplicaciones de aprendizaje automático para el análisis industrial de la provisión azucarera en Matanzas, Cuba. *Rev. U.D.C.A Act. & Div. Cient.* 25(2):e2334. <http://doi.org/10.31910/rudca.v25.n2.2022.2334>
- García, Y. y Cabrera, J.A. (2023). Procedimiento para valorar la variabilidad espacio-temporal en un proceso ecosistémico de soporte. *Ingeniería Industrial*, 44(2), 1-17.
- Gil, V. (2016). Pronóstico de la demanda mensual de electricidad con series de tiempo. *Revista EIA*, 13 (26), 111-120. <https://doi.org/10.24050/reia.v13i26.749>
- Gondkar, S., Sreeramagiri S., & Zondervan, E. (2012). Methodology for Assessment and Optimization of Industrial Eco-Systems. *Challenges*, 3, 49-69. <http://www.mdpi.com/2078-1547/3/1/49/pdf>
- González-Corzo, M. (Ed) (2015). La agroindustria cañera cubana: transformaciones recientes. New York (USA): Bildner Center for Western Hemisphere Studies. http://www.gc.cuny.edu/CUNY_GC/media/365-Images/SugarEbook.pdf
- González-Esquivel, C. E., Gavito, M. E., Astier, M., Cadena-Salgado, M., del-Val, E., Villamil-Echeverri, L., Merlín-Uribe, Y., & Balvanera, P. (2015). Ecosystem service trade-offs, perceived drivers, and sustainability in contrasting agroecosystems in central Mexico. *Ecology and Society*, 20 (1), 38. <http://dx.doi.org/10.5751/ES-06875-200138>
- Goovaerts, P. (2018). Flint Drinking Water Crisis: A First Attempt to Model Geostatistically the Space-Time Distribution of Water Lead Levels. In: B. S. Daya *et al.* (Eds.). *Handbook of Mathematical Geosciences* (pp. 255-276). Gewerbestrasse (Switzerland): Springer. https://doi.org/10.1007/978-3-319-78999-6_14

- Gräler, B., Pebesma, E., & Heuvelink, G. (2016). gstat: Sapatial and spatio-temporal geostatistical modelling, prediction and simulation. R package version 1.1-6. <https://CRAN.R-project.org/package=gstat>
- Granja, M.D. y Vidal, H. (2014). Pérdidas indeterminadas en la producción de azúcar. Imbabura (Ecuador): Derechos Reservados de Autor. https://www.academia.edu/29924196/P%C3%89RDIDAS_INDETERMINADAS_EN_LA_PRODUCCI%C3%93N_DE_AZ%C3%9ACAR
- Grima, N., Singh S., Smetschka B., & Ringhofer L. (2016). Payment for Ecosystem Services (PES) in Latin America: Analysing the performance of 40 case studies. *Ecosystem Services*, 17, 24–32. <http://dx.doi.org/10.1016/j.ecoser.2015.11.010>
- Gross, J., Ligges, U. (2015). nortest: Tests for Normality. R package version 1.0-4. <https://CRAN.R-project.org/package=nortest>
- Grunewald, K., & Bastian, O. (2015). Ecosystem Services – Concept, Methods and Case Studies. Berlin (Germany): Springer. doi:10.1007/978-3-662-44143-5.
- Grunewald, K., Bastian, O., & Syrbe, R.-U. (2015). Space and Time Aspects of ES. In: Grunewald, K. y Bastian, O. (Eds.) *Ecosystem Services – Concept, Methods and Case Studies* (pp. 53-65). Berlin (Germany): Springer. doi:10.1007/978-3-662-44143-5
- Guan, F., Xia, M., Tang, X., & Fan, S. (2017). Spatial variability of soil nitrogen, phosphorus and potassium contents in Moso bamboo forests in Yong'an City, China. *Catena*, 150, 161–172. <http://dx.doi.org/10.1016/j.catena.2016.11.017>.
- Gujarati D.N. y Porter, D.C. (2010). Econometría. Quinta edición. D.F (México): Mcgraw-Hill/Interamericana editores.
- Guzmán G., Cabezas, J.M., Sánchez-Cuesta, R., Lora, Á., Bauer, T., Strauss, P., Winter, S., Zaller, J.G., & Gómez, J.A. (2019). A field evaluation of the impact of temporary

- cover crops on soil properties and vegetation communities in southern Spain vineyards. *Agriculture, Ecosystems and Environment*, 272, 135–145. <https://doi.org/10.1016/j.agee.2018.11.010>
- Hamel, P., & Bryant, B.P. (2017). Uncertainty assessment in ecosystem services analyses: Seven challenges and practical responses. *Ecosystem Services*, 24, 1–15. <http://dx.doi.org/10.1016/j.ecoser.2016.12.008>
- Hammer, R., Sentelhas, P., & Mariano, J. (2020). Sugarcane yield prediction through data mining and crop simulation models. *Sugar Tech*, 22, 216–225. <https://doi.org/10.1007/s12355-019-00776-z>
- Hassan, Z., Siraj-UD-Douhah, & Hasan, K. (2019). Forecasting the production of sugar cane based on time series models in Bangladesh. *Bulletin of Mathematics and Statistics Research*, 7(4), 24–32. doi:10.33329/bomsr.74.24
- Hoffmann, H., Schomers, S., Meyer, C., Sander, K., Hickey, V., & Feuerbacher, A. (2019). Agriculture and Ecosystem Services. *Encyclopedia of Food Security and Sustainability*, 3, 9–13. <https://doi.org/10.1016/B978-0-08-100596-5.22202-6>.
- Hori, K., Saito, O., Hashimoto, S., Matsui, T., Akter, R., & Takeuchi, K. (2021). Projecting population distribution under depopulation conditions in Japan: scenario analysis for future socio-ecological systems. *Sustainability Science*, 16, 295–311. <https://doi.org/10.1007/s11625-020-00835-5>
- Hosseini, M., Agereh, S., Khaledian, Y., Zoghalchali, H., Brevik, E., & Naeini, S. (2017). Comparison of multiple statistical techniques to predict soil phosphorus. *Applied Soil Ecology*, 114, 123–131. <http://dx.doi.org/10.1016/j.apsoil.2017.02.011>
- Hou, D., O'Connor, D., Nathanail, P., Tian, L., & Ma, Y. (2017). Integrated GIS and multivariate statistical analysis for regional scale assessment of heavy metal soil

- contamination: A critical review. *Environmental Pollution*, 231, 1188-1200.
<http://dx.doi.org/10.1016/j.envpol.2017.07.021>
- Hyndman, R., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., & Yasmeeen, F. (2018). forecast: Forecasting functions for time series and linear models. R package version 8.4.
<https://CRAN.R-project.org/package=forecast>
- Inamuddin, Ahamed, M.I., Boddula, R., & Altalhi, T. (Eds) (2021). Applied Soil Chemistry. Hoboken (USA): John Wiley & Sons. doi:10.1002/9781119711520
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical with Applications in R*. Second Edition. New York (USA): Springer.
<https://doi.org/10.1007/978-1-0716-1418-1>
- Jax, K. (2019). Taking Social Responsibility in Using Ecosystem Services Concepts: Ethical Issues of Linking Ecosystems and Human Well-Being. In: Schröter *et al.* (Eds) *Atlas of Ecosystem Services* (pp. 25-31). Gewerbestrasse (Switzerland): Springer.
https://doi.org/10.1007/978-3-319-96229-0_6
- Jónsson, J.Ö.G., Davíðsdóttir, B., Nikolaidis, N.P., & Giannakis, G.V. (2019). Tools for Sustainable Soil Management: Soil Ecosystem Services, EROI and Economic Analysis". *Ecological Economics*, 157, 109-119.
<https://doi.org/10.1016/j.ecolecon.2018.11.010>
- Kamiyama, C. (2020). Food Provisioning Services. Via Homegardens and Communal Sharing in Satoyama Socio-ecological Production Landscapes on Japan's Noto Peninsula. In: O. Saito (ed.), *Sharing Ecosystem Services. Building More Sustainable and Resilient Society* (pp. 35-54). Singapore: Springer. https://doi.org/10.1007/978-981-13-8067-9_3

- Karagöz, I. (2021). Fertilization and Fertilizer Types. In: Inamuddin et al. (Eds.), *Applied Soil Chemistry* (pp 123-148). Hoboken (USA): John Wiley & Sons. doi:10.1002/9781119711520
- Kassambara, A. (2018). ggpubr: 'ggplot2' Based Publication Ready Plots. R package version 0.2. <https://CRAN.R-project.org/package=ggpubr>
- Keith, A., Schmidt, O., & McMahon, B. (2016). Soil stewardship as a nexus between Ecosystem Services and One Health. *Ecosystem Services*, 17, 40–42. <http://dx.doi.org/10.1016/j.ecoser.2015.11.008>
- Kendall, A., & Spang, E. (2019). The role of industrial ecology in food and agriculture's adaptation to climate change. *Journal of Industrial Ecology*, 24 (2), 313-317. doi:10.1111/jiec.12851
- Kenter, J., Reed, M., & Fazey I. (2016). The Deliberative Value Formation model. *Ecosystem Services*, 21, 194–207. <http://dx.doi.org/10.1016/j.ecoser.2016.09.015>.
- Khan, A., Lu, G., Ayaz, M., Zhang, H., Wang, R., Lv, F., Yang, X., Sun, B., & Zhang, S. (2018). Phosphorus efficiency, soil phosphorus dynamics and critical phosphorus level under long-term fertilization for single and double cropping systems. *Agriculture, Ecosystems and Environment*, 256, 1–11. <https://doi.org/10.1016/j.agee.2018.01.006>
- Kibet, C., Blanco-Canqui, H., & Jasa, P. (2016). Long-term tillage impacts on soil organic matter components and related properties on a Typic Argiudoll. *Soil and Tillage Research*, 155, 78–84. <http://dx.doi.org/10.1016/j.still.2015.05.006>
- Kitchen N., & Clay, S.A. (2019). Understanding and Identifying Variability. In: Shannon et al. (Eds), *Precision agriculture basic* (pp. 13-24). Madison (USA): Soil Science Society of America. doi:10.2134/precisionagbasics

- Krispin, R. (2019). *Hands-On Time Series Analysis with R: Perform time series analysis and forecasting using R*. Birmingham, (UK): Packt Publishing.
- Krispin, R. (2020). TSstudio: Functions for Time Series Analysis and Forecasting. R package version 0.1.6. <https://CRAN.R-project.org/package=TSstudio>
- Kumar, A.V., Kumar, P.G., Hari, K.S.P., Kumar, V.D., Kumar, S.D., & Kumar, A. (2021). Sugarcane Yield Forecasting Model Based on Weather Parameters. *Sugar Tech*, 23, 158-166. <https://doi.org/10.1007/s12355-020-00900-4>
- Kumar, N., & Sinha, N.K. (2018). Geostatistics: Principles and Applications in Spatial Mapping of Soil Properties. In: Reddy, G. P. O., & Singh S. K. (Eds.). *Geospatial Technologies in Land Resources Mapping, Monitoring and Management, Geotechnologies and the Environment 21* (pp. 143-159). Gewerbestrasse (Switzerland): Springer. https://doi.org/10.1007/978-3-319-78711-4_8
- Kustiyo, A., & Arkeman, Y. (2019). Design for improvement of sugar factory performance based on statistical thinking. *Earth and Environmental Science*, 335, 012033, 1-10. doi:10.1088/1755-1315/335/1/012033.
- La Notte, A., D'Amato, D., Mäkinen, H., Paracchini, M., Liqueste, C., Egoh, B., Geneletti, D., & Crossman, N.D. (2017). Ecosystem services classification: A systems ecology perspective of the cascade framework. *Ecological Indicators*, 74, 392-402. <http://dx.doi.org/10.1016/j.ecolind.2016.11.030>
- La Notte, A., Maes, J., Dalmazzone, S., Crossman, N., Grizzetti, B., & Bidoglio, G. (2017). Physical and monetary ecosystem service accounts for Europe: A case study for in-stream nitrogen retention". *Ecosystem Services*, 23, 18-29. <http://dx.doi.org/10.1016/j.ecoser.2016.11.002>.

- LaDeau, S., Han, B., Rosi-Marshall, E., & Weathers, K. (2017). The Next Decade of Big Data in Ecosystem Science. *Ecosystems*, 20, 274–283. doi:10.1007/s10021-016-0075-y
- Lauf, T., Ek, K., Gawel, E., Lehmann, P., & Söderholm, P. (2019). Wind Power Deployment as a Stressor for Ecosystem Services: A Comparative Case Study from Germany and Sweden. In: Schröter, M. *et al.* (Eds.), *Atlas of Ecosystem Services* (pp. 125-128). Gewerbestrasse (Switzerland): Springer. https://doi.org/10.1007/978-3-319-96229-0_20
- Lee, J. (2020). *Industrial AI: Applications with Sustainable Performance*. Singapore: Springer. <https://doi.org/10.1007/978-981-15-2144-7>
- Liang, Y., Liu, L., & Huang, J. (2020). *Integrated Modelling of Ecosystem Services and Land-Use Change*. Singapore: Springer. <https://doi.org/10.1007/978-981-13-9125-5>
- Lilburne, L., Eger, A., Mudge, P., Ausseil, A., Stevenson, B., Herzig, A., & Beare, M. (2020). The Land Resource Circle: Supporting land-use decision making with an ecosystem-service-based framework of soil functions. *Geoderma*, 363, 114134. <https://doi.org/10.1016/j.geoderma.2019.114134>
- Lin, Y., Lin, W., Li, M., Chen, Y., Chiang, L., & Wang, Y. (2014). Identification of spatial distributions and uncertainties of multiple heavy metal concentrations by using spatial conditioned Latin Hypercube sampling. *Geoderma*, 230–231, 9–21. <http://dx.doi.org/10.1016/j.geoderma.2014.03.015>
- Liquete, C., Udias, A., Conte, G., Grizzetti, B., & Masi, F. (2016). Integrated valuation of a nature-based solution for water pollution control. Highlighting hidden benefits. *Ecosystem Services*, 22, 392–401. <http://dx.doi.org/10.1016/j.ecoser.2016.09.011>.

- Logsdon, S.D., & Cole, K.J. (2018). Soil nutrient variability and groundwater nitrate-N in agricultural fields. *Science of the Total Environment*, 627, 39–45. <https://doi.org/10.1016/j.scitotenv.2018.01.182>
- Loos, J., Batáry, P., Grass, I., Westphal, C., Bänisch, S., Baillod, A., Hass, A., Rosa, J., & Tscharnkte, T. (2019). Vulnerability of Ecosystem Services in Farmland Depends on Landscape Management. In: M. Schröter et al. (Eds.), *Atlas of Ecosystem Services* (pp. 91-96). Gewerbestrasse (Switzerland): Springer. https://doi.org/10.1007/978-3-319-96229-0_15
- Luis-Rojas, S., García-Sánchez, R., García-Mata, R., Arana-Coronado, O. y González-Estrada, A. (2019). Metodología Box - Jenkins para pronosticar los precios de huevo blanco pagados al productor en México. *Agrociencia*, 53 (6), 911-925.
- Lumley, T. (2017). leaps: Regression Subset Selection. R package version 3.0. <https://CRAN.R-project.org/package=leaps>
- Macháč, J., Trantinová, M., & Zaňková, L. (2021). Externalities in agriculture: How to include their monetary value in decision-making? *International Journal of Environmental Science and Technology*, 18, 3-20. <https://doi.org/10.1007/s13762-020-02752-7>
- Macintosh, K.A, Doody, D.G., Withers, P.J.A., McDowell, R.W., Smith, D.R., Johnson, L.T., Bruulsema, T.W., O'Flaherty, V., & McGrath, J.W. (2019). Transforming soil phosphorus fertility management strategies to support the delivery of multiple ecosystem services from agricultural systems. *Science of the Total Environment*, 649, 90–98. <https://doi.org/10.1016/j.scitotenv.2018.08.272>
- Mamat, Z., Yimit, H., Ji, R.Z.A., & Eziz, M. (2014). Source identification and hazardous risk delineation of heavy metal contamination in Yanqi basin, northwest China.

Science of the Total Environment, 493, 1098-1111.

<http://dx.doi.org/10.1016/j.scitotenv.2014.03.087>

Martínez, C.M. y De Leon, J.B. (2012). Influencia de la calidad de la materia prima en el proceso tecnológico, calidad del producto final, y el rendimiento industrial en una fábrica de azúcar. *Centro Azúcar*, 39(3), 28-34.

http://centrozucar.uclv.edu.cu/index.php/centro_azucar/article/download/344/336/373

Martínez, J.R., Gálvez, G., de Armas, R., Espinosa, R., Vigoa, R. y León, A. (1987). *La Caña de Azúcar en Cuba*. La Habana (Cuba): Editorial Científico-Técnica.

McDonald, J. (2014). *Handbook of biological statistics*. Third edition. Maryland (USA): Sparky House Publishing.

https://www.researchgate.net/publication/267210763_The_Provision_of_Forest_Ecosystem_Services_-_What_Science_Can_Tell_Us_5_2014_Volume_I_Quantifying_and_valuing_non-marketed_ecosystem_services_and_Volume_II_Assessing_cost_of_provision_and_designing_eco/download

Millennium Ecosystem Assessment. MIEA. (2005). *Ecosystems and Human Well-being: Opportunities and Challenges for Business and Industry*. Washington (USA): World Resources Institute.

<http://www.millenniumassessment.org/documents/document.439.aspx.pdf>

Moebius-Clune, B.N., Moebius-Clune, D.J., Gugino, B.K., Idowu, O.J., Schindelbeck, R.R., Ristow, A.J., van Es, H.M., Thies, J.E., Shayler, H. A., McBride, M. B., Wolfe, D.W., & Abawi, G.S. (2016). *Comprehensive Assessment of Soil Health – The Cornell Framework Manual*, Edition 3.1, NY (USA): Cornell University.

<http://soilhealth.cals.cornell.edu>

- Mokondoko, P., Manson, R., Ricketts, T., & Geissert, D. (2018). Spatial analysis of ecosystem service relationships to improve targeting of payments for hydrological services. *PLoS ONE*, 13 (2): e0192560.
<https://doi.org/10.1371/journal.pone.0192560>
- Montes, E., Fernando, E. y Alfonso, C. (2016). Aplicación de series de tiempo en la realización de pronósticos de producción. *Revista Fuentes*, 14(1), 79-88.
<https://dialnet.unirioja.es/descarga/articulo/637111.pdf>
- Muddiman, S. (2019). *Ecosystem Services Economics and Policy. Palgrave Studies in Natural Resource Management*. Gewerbestrasse (Switzerland): Springer.
<https://doi.org/10.1007/978-3-030-13819-6>
- Müller, A. y Sukhdev, P. (2018). Midiendo lo que importa en la agricultura y los sistemas alimentarios: síntesis de los resultados y recomendaciones del Informe sobre los Fundamentos Científicos y Económicos de la iniciativa TEEB para la Agricultura y la Alimentación. Ginebra (Suiza): TEEBAgriFood.
http://digital.csic.es/bitstream/10261/156293/1/Maranon_Mat_org_octubre2017.pdf
- Mwanga, D., Ong'ala, J., & Orwa, G. (2017). Modeling Sugarcane Yields in the Kenya Sugar Industry: A SARIMA Model Forecasting Approach. *International Journal of Statistics and Applications*, 7(6), 280-288. doi: 10.5923/j.statistics.20170706.02
- Nashiruddin, N.I., Fadziyana, A., Rahman, R.A., Ilias, R.Md., & Wan, H. (2020). Process parameter optimization of pretreated pineapple leaves fiber for enhancement of sugar recovery. *Industrial Crops and Products*, 152, 112514.
<https://doi.org/10.1016/j.indcrop.2020.112514>

- Natarajan, R., Subramanian, J., & Papageorgiou, E. (2016). Hybrid learning of fuzzy cognitive maps for sugarcane yield classification. *Computers and Electronics in Agriculture*, 127, 147–157. <http://dx.doi.org/10.1016/j.compag.2016.05.016>
- Navarro, H. y Rostgaard, L. (2014). Impacto de la materia extraña en la calidad de los jugos de caña y en los indicadores de eficiencia de un central azucarero. *Centro Azúcar*, 41. http://centrozucar.uclv.edu.cu/index.php/centro_azucar/article/download/245/236/272
- Neto, E.A., Canabarro., Júnior, E., & Oliveira, M.S. (2018). Spatial dependence index for cubic, pentaspherical and wave semivariogram models. *Bulletin of Geodetic Sciences*, 24 (1), 142–151. doi:10.1590/S1982-21702018000100010
- Nwanganga, F., & Chapple, M. (2020). *Practical Machine Learning in R*. Indiana (USA): John Wiley & Sons. doi:10.1002/9781119591542
- Olea, R.A. (2006). A six-step practical approach to semivariogram modeling. *Stoch Environ Res Risk Assess*, 20, 307–318. doi:10.1007/s00477-005-0026-1
- Oliver, M.A., & Webster, R. (2015). *Basic Steps in Geostatistics: The Variogram and Kriging*. New York (USA): Springer. doi:10.1007/978-3-319-15865-5_1
- Osorio- González, C.S., Suralikerimath, N., Hegde, K., & Brar, S.K. (2020). Sustainability of Ecosystem Services (ESs). In: Surampalli *et al.* (Eds) *Sustainability: Fundamentals and Applications* (pp. 277-294). Hoboken (USA): John Wiley & Sons. <https://doi.org/10.1002/9781119434016.ch13>
- Pal, D. K. (2019). *Ecosystem Services and Tropical Soils of India*. Gewerbestrasse (Switzerland): Springer. <https://doi.org/10.1007/978-3-030-22711-1>

- Pandeya, B., Buytaert, W., Zulkafli, Z., Karpouzoglou, T., Mao, F., & Hannah, D. (2016). A comparative analysis of ecosystem services valuation approaches for application at the local scale and in data scarce regions. *Ecosystem Services*, 22, 250–259. <http://dx.doi.org/10.1016/j.ecoser.2016.10.015>.
- Paruelo, J., Herrera, L., Moricz, M., Urrutia, R., Zaccagnini, M., Somma, D., Quispe, C., Giaccio, G., Milano, F., Barreda, M. y Ceballos, D. (2010). Desde la discusión conceptual y metodológica a la acción. El uso del concepto de SE en el proceso de toma de decisiones. En: Lateral, P. *et al.*, (Eds), *Valoración de Servicios ecosistémicos* (pp. 689-705). Buenos Aires (Argentina): Instituto Nacional de Tecnología Agropecuaria. <http://www.iai.int/files/LateralJobbagyParueloValorEcosyst.pdf>
- Paterson, S., Minasny, B., & McBratney, A. (2018). Spatial variability of Australian soil texture: A multiscale analysis. *Geoderma*, 309, 60–74. <http://dx.doi.org/10.1016/j.geoderma.2017.09.005>
- Pérez, H., Santana, I. y Rodríguez, I. (2015). *Manejo Sostenible de Tierras en la Producción de Caña de Azúcar*. Machala (Ecuador): Ediciones UTMACH. <http://repositorio.utmachala.edu.ec/bitstream/48000/6649/1/16%20MANEJO%20SOSTENIBLE%20DE%20LA%20TIERRA%20EN%20LA%20PRODUCCION%20DE%20CA%20C3%91A%20DE%20AZUCAR%20VOL%20II.pdf>
- Perlatti, P., Forim, M., & Zuin, V. (2014). Green chemistry, sustainable agriculture and processing systems: a Brazilian overview. *Chemical and Biological Technologies in Agriculture*, 1(5), 1-9. <http://doi.org/10.1186/s40538-014-0005-1>
- Piotrowska-Długosz, A., Breza-Boruta, B., & Długosz, J. (2019). Spatial and temporal variability of the soil microbiological properties in two soils with a different

- pedogenesis cropped to winter rape (*Brassica napus L.*). *Geoderma*, 340, 313–324.
<http://doi.org/10.1016/j.geoderma.2019.01.020>
- Pomara, L.Y., & Lee, D.C. (2021). The Role of Regional Ecological Assessment in Quantifying Ecosystem Services for Forest Management. *Land*, 10 (7), 725.
<https://doi.org/10.3390/land10070725>
- Potschin, M., & Haines-Young, R. (2017). From nature to society. In: Burkhard, B., & Maes, J. (Eds.), *Mapping Ecosystem Services* (pp, 41-43.). Sofia (Bulgaria): Pensoft Publishers.
- Power, A.G. (2010). Ecosystem services and agriculture: tradeoffs and synergies. *Phil. Trans. R. Soc. B*, 365, 2959–2971. doi:10.1098/rstb.2010.0143
- Quijala, Y., Rosa-Domínguez, E., Díaz-Aguirre, S., Pérez-Martínez, D., Contreras-Moya, A., Álvarez-Álvarez, J. y Amusquibar, G. (2016). Aplicación de la metodología de inspección estatal de la actividad reguladora ambiental con enfoque de ciclo de vida en la industria azucarera. *ICIDCA*, 50, (2) 58-71.
<http://www.redalyc.org/pdf/2231/223150958009.pdf>
- R Core Team (2019). R: A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, (Austria). <https://www.R-project.org/>
- Rahman, M.M., & Robson, A.J. (2016). A Novel Approach for Sugarcane Yield Prediction Using Landsat Time Series Imagery: A Case Study on Bundaberg Region. *Advances in Remote Sensing*, 5, 93-102. <http://dx.doi.org/10.4236/ars.2016.52008>
- Ramasubramanian, K., & Singh, A. (2019). *Machine Learning Using R: With Time Series and Industry-Based Use Cases in R*. Second Edition. New York (USA): Springer.
<https://doi.org/10.1007/978-1-4842-4215-5>

- Ramesh, S., & Kaplanay K. (2015). Ecological integrity and environmental protection for Vijayawada region – Scattered Eastern Ghats. *International Journal of Sustainable Built Environment*, 4, 109–116. <http://dx.doi.org/10.1016/j.ijsbe.2015.03.003>.
- Rahul, T., Kumar, N.A., Biswaranjan, D., Mohammad, S., Banwari, L., Priyanka, G., Sangita, M., Bihari, P.B., Narayan, S.R., & Kumar, S.A. (2019). Assessing soil spatial variability and delineating site-specific management zones for a coastal saline land in eastern India. *Arch Agron Soil Sci*, 65(13), 1775–1787. <https://doi.org/10.1080/03650340.2019.1578345>
- Resende, V. y Coelho, M. (2014). Muestreo para mapeo y manejo de la fertilidad del suelo”. En: Chartuni M. y Magdalena, C. (Eds). *Manual de Agricultura de precisión* (pp. 38-48). Montevideo (Uruguay): Instituto Interamericano de Cooperación para la Agricultura, PROCISUR. <http://www.gisandbeers.com/RRSS/Publicaciones/Manual-Agricultura-Precision.pdf>.
- Reza, S. K., Dutta, D., Bandyopadhyay, S., & Singh, S. K. (2019). Spatial Variability Analysis of Soil Properties of Tinsukia District, Assam, India. *Agric Res*. 8, 231-238. <https://doi.org/10.1007/s40003-018-0365-z>
- Ribas, M., Consuegra, R. y Alfonso, M. (2016). Análisis de los factores que más inciden sobre el rendimiento industrial azucarero. *Centro Azúcar*, 43, 51-60. <http://scielo.sld.cu/pdf/caz/v43n1/caz06116.pdf>
- Rico, O., Peñalver, Y., Leiva, J. y González, V. (2013). Efecto del tiro directo de la caña en el rendimiento y la eficiencia energética. *Centro Azúcar*, 40, 77-82. http://centrozucar.uclv.edu.cu/index.php/centro_azucar/article/download/320/312/349.

- Riechers, M., Barkmann, J., & Tschardt, T. (2016). Perceptions of cultural ecosystem services from urban green. *Ecosystem Services*, 17, 33–39. <http://dx.doi.org/10.1016/j.ecoser.2015.11.007>
- Rincón-Ruiz, A., Echeverry-Duque, M., Piñeros, A. M., Tapia, C. H., David, A., Arias-Arévalo, P. y Zuluaga, P. A. (2014). *Valoración integral de la biodiversidad y los servicios ecosistémicos: Aspectos conceptuales y metodológicos*. Bogotá (Colombia): Instituto de Investigación de Recursos Biológicos Alexander von Humboldt. http://www.iaii.int/admin/site/sites/default/files/uploads/2015/08/VIBSE_2014_1.pdf
- Ronchi, S. (2018). *Ecosystem Services for Spatial Planning, Green Energy and Technology*. Gewerbestrasse (Switzerland): Springer. http://doi.org/10.1007/978-3-319-90185-5_2
- Rosemary, F., Vitharana, U.W.A., Indraratne, S.P., Weerasooriya, R., & Mishra, U. (2017). Exploring the spatial variability of soil properties in an Alfisol soil catena. *Catena*, 150, 53–61. <http://dx.doi.org/10.1016/j.catena.2016.10.017>.
- Roy, M.M., & Chandra, A. (2020). Optimizing Sugar Recovery in India: Need for an Integrated Approach. *Acta Scientific Agriculture*, 4 (3), 01-06. doi:10.31080/ASAG.2020.04.0806
- Ruiz, H.R. (2018). Pronóstico de las exportaciones del cacao ecuatoriano para el 2018 con el uso de modelos de series de tiempo. *INNOVA Research Journal*, 3 (6), 9-20. <https://dialnet.unirioja.es/servlet/articulo?codigo=6778620>
- Sánchez, P. (1981). *Suelos del trópico: Características y manejo*. San José (Costa Rica): IICA.
- Sanjeev, Verma, U., & Tonk, M. (2015). Time-series modelling for sugarcane yield estimation in Haryana. *International Journal of Applied Mathematics and Statistical*

https://www.academia.edu/17846430/TIME_SERIES_MODELLING_FOR_SUGARCANE_YIELD_ESTIMATION_IN_HARYANA?auto=download

Sarkar, D. (2008). lattice: Trellis graphics for R. R package version 0.20-35.

<https://CRAN.R-project.org/package=lattice>

Schloerke, B., Crowley, J., Cook, D., Briatte, F., Marbach, M., Thoen, E., Elberg, A., &

Larmarange, J., (2018). GGally: Extension to 'ggplot2'. R package version 1.4.0.

<https://CRAN.R-project.org/package=GGally>

Schröter, M., Ring, I., Schröter-Schlaack, C., & Bonn, A. (2019). The Ecosystem Service

Concept: Linking Ecosystems and Human Wellbeing. In Schröter, *et al.* (Eds). *Atlas of Ecosystem Services Drivers, Risks, and Societal Responses* (pp. 7-12). Gewerbestrasse

(Switzerland): Springer. <https://doi.org/10.1007/978-3-319-96229-0>.

Servicio de Recomendación de Fertilizantes y Enmiendas. SERFE. (2014). *Manual*

Servicio de Fertilización de la Caña de Azúcar. La Habana (Cuba): Instituto de Investigaciones de la Caña de Azúcar.

Servicio de Recomendación de Fertilizantes y Enmiendas. SERFE. (2015). *Recomendación*

de fertilizantes y enmiendas. Provincia Matanzas, UEB Jesús Rabí. Matanzas (Cuba): Instituto de Investigaciones de la Caña de Azúcar.

Shahzad, S., Shokat, S., Fiaz, N., & Hameed, A. (2017). Impact of Yield and Quality-

Related Traits of Sugarcane on Sugar Recovery. *J. Crop Sci. Biotech*, 20 (1), 1 – 7. doi:

No. 10.1007/s12892-016-0048-2

Shannon, D., Clay, D., & Sudduth, K. (2019). An Introduction to Precision Agriculture.

Shannon, D. et al (Eds). *Precision agriculture basic*. Madison (USA): Soil Science Society of America. doi:10.2134/precisionagbasics

- Slowikowski, K. (2018). ggrepel: Automatically Position Non-Overlapping Text Labels with 'ggplot2'. R package version 0.8.0. <https://CRAN.R-project.org/package=ggrepel>
- Smith, R., Dick J., & Scott, E. (2011). The role of statistics in the analysis of ecosystem services. *Environmetrics*, 22, 608–617. doi:10.1002/env.1107
- Soy-Massoni E, Langemeyer J, Varga D., Sáez M., & Pintó J. (2016). The importance of ecosystem services in coastal agricultural landscapes: Case study from the Costa Brava, Catalonia”. *Ecosystem Services*, 17, 43–52. <http://dx.doi.org/10.1016/j.ecoser.2015.11.004>
- Su, C., Liu, H., & Wang, S. (2018). A process-based framework for soil ecosystem services study and management. *Science of the Total Environment*, 627, 282–289. <https://doi.org/10.1016/j.scitotenv.2018.01.244>
- Tarafdar, A., Kaur, B.P., Nema, P.K., Babar, O.A., & Kumar, D. (2020). Using a combined neural network – genetic algorithm approach for predicting the complex rheological characteristics of microfluidized sugarcane juice. *Food Science and Technology*, 123, 109058. <https://doi.org/10.1016/j.lwt.2020.109058>
- Thakkar, J.J. (2020). *Structural Equation Modelling: Application for Research and Practice* (with AMOS and R). Singapore: Springer. <https://doi.org/10.1007/978-981-15-3793-6>
- Tola, E., Al-Gaadi, K.A., Madugundu, R., Zeyada, A.M., Kayad, A.G., & Biradar, C.M. (2017). Characterization of spatial variability of soil physicochemical properties and its impact on Rhodes grass productivity. *Saudi Journal of Biological Sciences*, 24, 421–429. <http://dx.doi.org/10.1016/j.sjbs.2016.04.013>

- Umar, W., Ayub, M., Rehman, M., Ahmad, H., Farooqi, Z., Ahsan Shahzad, Rehman, U., Mustafa, A., & Nadeem, M. (2020). Nitrogen and Phosphorus Use Efficiency in Agroecosystems. In: Kumar, S. *et al.*, (Eds.), *Resources Use Efficiency in Agriculture* (pp. 213-257). Singapore: Springer. https://doi.org/10.1007/978-981-15-6953-1_7
- Vang, L., Mertz, O, Christensen, A., Danielsen, F, Dawson, N, & Xaydongvanh, P. (2016). A combination of methods needed to assess the actual use of provisioning ecosystem services. *Ecosystem Services*, 17, 75–86. <http://dx.doi.org/10.1016/j.ecoser.2015.11.005>
- Vasu, D., Singh, S.K., Sahu, Nisha, Tiwary, Pramod, Chandran, P., Duraisami, V.P., Ramamurthy, V., Lalitha, M., & Kalaiselvi, B. (2017). Assessment of spatial variability of soil properties using geospatial techniques for farm level nutrient management”. *Soil and Tillage Research*, 169, 25–34. <http://dx.doi.org/10.1016/j.still.2017.01.006>
- Veronesi, F., Corstanje, R., & Mayr, T. (2014). Landscape scale estimation of soil carbon stock using 3D modelling. *Sci. Total Environ*, 487, 578–586. <http://dx.doi.org/10.1016/j.catena.2016.11.017>
- Vihervaara, P., Mononen, L., Santos, F., Adamescu, M., Cazacu, C., Luque, S., Geneletti, D., & Maes, J. (2017). Biophysical quantification. In: Burkhard & Maes J (Eds.) *Mapping Ecosystem Services* (pp. 95-146). Sofia (Bulgaria): Pensoft Publishers.
- Villasante, S., Lopes, P., & Coll, M. (2016). The role of marine ecosystem services for human well-being: Disentangling synergies and trade-offs at multiple scales”. *Ecosystem Services*, 17, 1–4. <http://dx.doi.org/10.1016/j.ecoser.2015.10.022>
- Wang, T., Kang, F., Cheng, X., Han, H., Bai, Y., & Ma, J. (2017). Spatial variability of organic carbon and total nitrogen in the soils of a subalpine forested catchment at

Mt. Taiyue, China. *Catena*, 155, 41–52.

<http://dx.doi.org/10.1016/j.catena.2017.03.004>

Wang, Z., & Shi, W. (2018). Robust variogram estimation combined with isometric log-ratio transformation for improved accuracy of soil particle-size fraction mapping. *Geoderma*, 324, 56–66. <https://doi.org/10.1016/j.geoderma.2018.03.007>

Wani, M., Bhat, M., Kirmani, N.A., & Wani, Z.M. (2013). Mapping of soil micronutrients in Kashmir agricultural landscape using ordinary kriging and indicator approach. *J Indian Soc Remote Sens*, 41 (2), 319–329. doi:10.1007/s12524-012-0242-3

Waweru, P., Burkhard, B., & Muller F. (2016). A review of studies on ecosystem services in Africa”. *International Journal of Sustainable Built Environment*, 5, 225–245. <http://dx.doi.org/10.1016/j.ijbsbe.2016.08.005>.

Wickham, H. (2016). *ggplot2: Elegant Graphics for Data Analysis*. New York (USA): Springer.

Wickham, H., François, R., Henry, L., & Müller, K. (2020). *dplyr: A Grammar of Data Manipulation*. R package version 0.8.5. <https://CRAN.R-project.org/package=dplyr>

Willcock, S., Martínez-López, J., Hooftman, D., Bagstad, K., Balbi, S., Marzo, A., Prato, C., Sciandrello, S., Signorello, G., Voigt, B., Villa, F., Bullock, J., & Athanasiadis, I. (2018). Machine learning for ecosystem services. *Ecosystem Services*, 33, 165–174. <https://doi.org/10.1016/j.ecoser.2018.04.004>

Wu, C., Huang, J., Zhu, H., Zhang, L., Minasny, B., Marchant, B., & McBratney, A.B. (2019). Spatial changes in soil chemical properties in an agricultural zone in southeastern China due to land consolidation. *Soil and Tillage Research*, 187, 152–160. <https://doi.org/10.1016/j.still.2018.12.012>

- Xia, X., Yang, Z., Yu, T., Hou, Q., & Muchimamui, A. (2017). Detecting changes of soil environmental parameters by statistics and GIS: A case from the lower Changjiang plain, China. *Journal of Geochemical Exploration*, 181, 116-128. <https://doi.org/10.1016/j.gexplo.2017.07.002>
- Xiangzheng, D., Zhihui, L., & Gibson, J. (2016). A review on trade-off analysis of ecosystem services for sustainable land-use management. *J. Geogr. Sci*, 26 (7), 953-968. doi:10.1007/s11442-016-1309-9
- Zeki, E. (2020). A Framework for Characterizing and Regulating Ecosystem Services in a Management Planning Context. *Forests*, 11, 102. doi:10.3390/f11010102.
- Zhang, C. (2006). Using multivariate analyses and GIS to identify pollutants and their spatial patterns in urban soils in Galway, Ireland". *Environmental Pollution*, 142, 501-511. doi:10.1016/j.envpol.2005.10.028
- Zhen, H., Gao, W., Yuan, K., Ju, X., & Qiao, Y. (2021). Internalizing externalities through net ecosystem service analysis—A case study of greenhouse vegetable farms in Beijing. *Ecosystem Services*, 50, 101323. <https://doi.org/10.1016/j.ecoser.2021.101323>
- Zimmerman, D.L. (2020). *Linear Model Theory with Examples and Exercises*. Gewerbestrasse (Switzerland): Springer. <https://doi.org/10.1007/978-3-030-52063-2>

ANEXOS

Anexo 1. Categorías de elemento asimilables del suelo

	P asimilable
Categorías	P_2O_5 mg.100g ⁻¹
Muy alto	$P_2O_5 \geq 13$
Alto	$8,3 \leq P_2O_5 < 13,0$
	$3,6 \leq P_2O_5 < 8,3$
Medio	$3,0 \leq P_2O_5 < 3,6$
	$2,4 \leq P_2O_5 < 3,0$
	$1,8 \leq P_2O_5 < 2,4$
	$1,2 \leq P_2O_5 < 1,8$
Bajo	$P_2O_5 < 1,2$

	K asimilable
Categorías	K_2O mg.100g ⁻¹
Muy alto	$K_2O \geq 25,7$
Alto	$15,5 \leq K_2O < 25,7$
Medio	$10,9 \leq K_2O < 15,5$
Bajo	$7,9 \leq K_2O < 10,9$
Muy bajo	$K_2O < 7,9$

Anexo 2. Librerías de R

No.	Librería	Referencia	No.	Librería	Referencia
1	sp	Bivand <i>et al.</i> (2013)	11	lattice	Sarkar (2008)
2	gstat	Gräler <i>et al.</i> (2016)	12	ggplot2	Wickham (2016)
3	rgdal	Bivand, <i>et al.</i> (2018)	13	nortest	Gross y Ligges (2015)
4	maptools	Bivand y Lewin-Koh (2017)	14	ggpubr	Kassambara (2018)
5	rgeos	Bivand y Rundel (2018)	15	GGally	Schloerke <i>et al.</i> (2018)
6	ggrepel	Slowikowski (2018)	16	akima	Akima y Gebhardt (2016)
7	leaps	Lumley (2017)	17	dplyr	Wickham <i>et al.</i> (2020)
8	gridExtra	Auguie (2017)	18	car	Fox y Weisberg (2011)
9	TSstudio	Krispin (2020)	19	nortest	Gross y Ligges (2015)
10	forecast	Hyndman <i>et al.</i> (2018)			

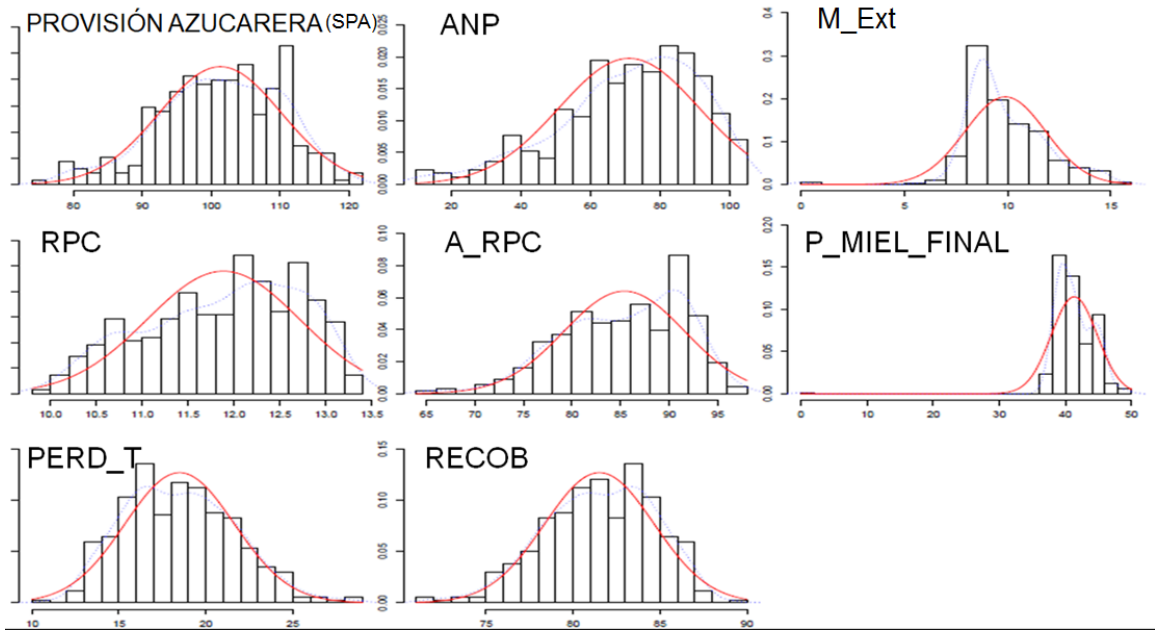
Anexo 3. Modelos teóricos de semivariograma utilizados

Modelo	Función de Semivariograma
Esférico	$\gamma(h) = \begin{cases} c_0 + c \left\{ \frac{3h}{2r} - \frac{1}{2} \left(\frac{h}{r} \right)^3 \right\} & \text{for } 0 < h \leq r \\ c_0 + c & \text{for } h > r \\ 0 & \text{for } h = 0, \end{cases}$ <p>Donde $\gamma(h)$ es la semivarianza en el intervalo de distancia h, y r es el rango (A_0). C_0 es el <i>nugget</i>, C es la varianza a la que los componentes están espacialmente correlacionados</p>
Exponencial	$\gamma(h) = \begin{cases} c_0 + c \{ 1 - \exp(-\frac{h}{a}) \}, & \text{for } 0 < h \\ 0 & \text{for } h = 0 \end{cases}$ <p>Este modelo tiende a alcanzar el <i>sill</i> asintóticamente. El rango a es definido como la distancia a la cual el valor del variograma alcanza el 95% del <i>sill</i>.</p>
Gaussiano	$\gamma(h) = 1 - \exp\left(\frac{-3h^2}{a^2}\right)$ <p>Al igual que el modelo exponencial, tiende a alcanzar el <i>sill</i> asintóticamente, y el rango se define como la distancia a la cual el variograma alcanza el 95% del <i>sill</i>. Donde h y a Ídem a exponencial.</p>
Lineal	$\gamma(h) = C_0 + bh$ <p>Donde b es la pendiente de la recta.</p>
Wave	$\gamma(h) = \begin{cases} C_0 + C_1 \left(1 - \frac{\sin\left(\pi \frac{h}{a}\right)}{\pi \frac{h}{a}} \right) \end{cases}$
Fuente: Gallardo (2006); Neto <i>et al.</i> (2018); Oliver y Webster (2015)	

Anexo 4. Modelos serie de tiempo y parámetros de selección

<i>Modelo</i>	<i>Tipo de set</i>	<i>ME</i>	<i>RMSE</i>	<i>MAE</i>	<i>MPE</i>	<i>MAPE</i>
ARIMA (0, 1, 1) (2, 1, 2) [4]	Set de entrenamiento	-0,5	9,1	6,8	-1,3	7,3
	Set de prueba	-3,4	9,0	6,6	-6,0	9,5
ETS	Set de entrenamiento	-1,50	8,95	6,85	-2,42	7,38
	Set de prueba	-6,70	11,62	8,49	-10,57	12,38
TSLM Con <i>Flag</i>	Set de entrenamiento	-4,59e-16	8,38	6,18	-0,79	6,58
	Set de prueba	-8,71e+00	12,69	9,71	-13,10	14,08
TSLM Polinomio	Set de entrenamiento	9,16e-16	8,26	5,91	-0,76	6,28
	Set de prueba	-9,03e-01	8,59	6,85	-3,05	9,48
ETS (Error, Trend, componente estacional): modelo con suavizado exponencial						
TSLM con Flag: Modelo de regresión lineal para serie de tiempo y uso de una variable <i>flag</i>						
TSLM Polinomio: Modelo de regresión de polinomio para la serie de tiempo						

Anexo 5. Comportamiento de las variables utilizadas en la regresión lineal



Anexo 6. Parámetros y prueba de normalidad de *Lilliefors*.

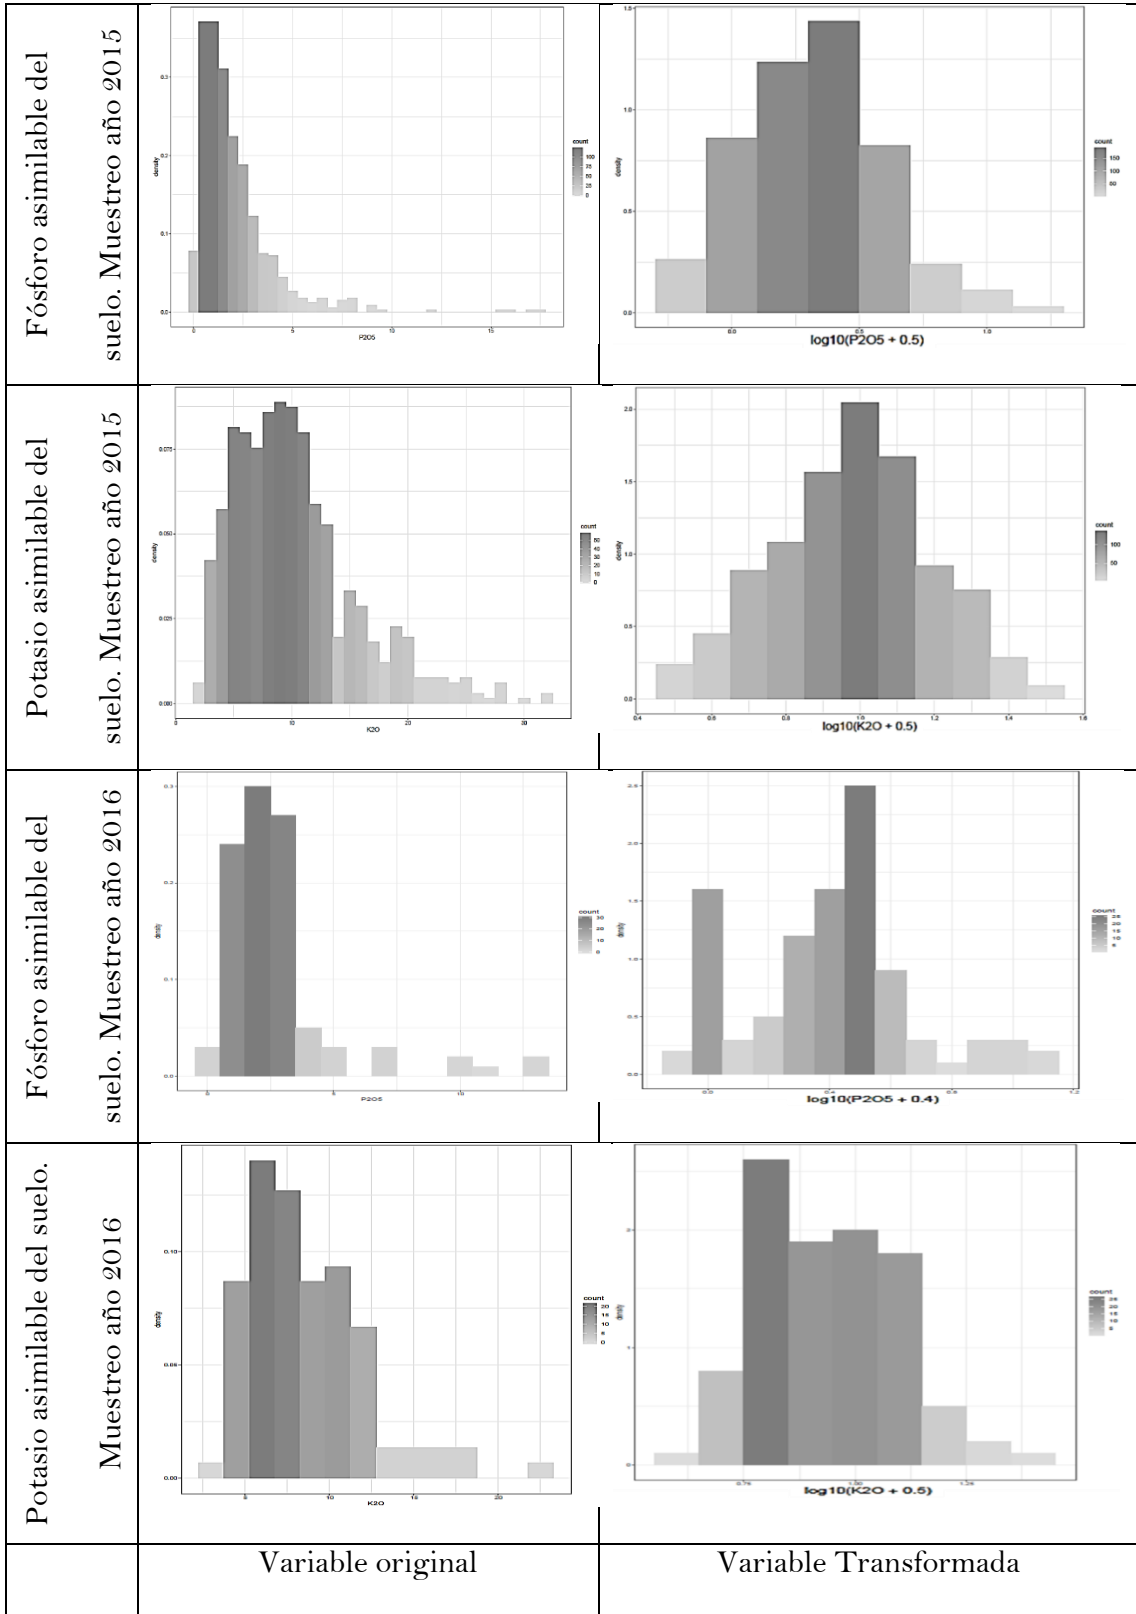
<i>Variable</i>	<i>Coefficientes</i>		<i>Test</i>	<i>Sig.</i>
	<i>Asimetría</i>	<i>Curtosis</i>	<i>Lilliefors</i>	
Fósforo asimilable (mg 100g ⁻¹) ^a	2,8	10,6	0,16	2,2 E ⁻¹⁶
Valores transformados [log ₁₀ (P ₂ O ₅ + 0,5)] ^a	0,4	0,006	0,03	0,13
Potasio asimilable (mg 100g ⁻¹) ^a	2,83	15,53	0,10	2,2 E ⁻¹⁶
Valores transformados [log ₁₀ (K ₂ O + 0,5)] ^a	-0,80	-0,36	0,03	0,1
Fósforo asimilable (mg 100g ⁻¹) ^b	3,70	17,70	0,23	1,4E ⁻¹⁴
Valores transformados [log ₁₀ (P ₂ O ₅ + 0,4)] ^b	0,32	0,28	0,10	0,02
Potasio asimilable (mg 100g ⁻¹) ^b	1,31	2,41	0,13	5,1 E ⁻⁴
Valores transformados [log ₁₀ (K ₂ O + 0,5)] ^b	0,32	-0,22	0,07	0,1

^a corresponden al muestreo de suelo compuesto en el año 2015

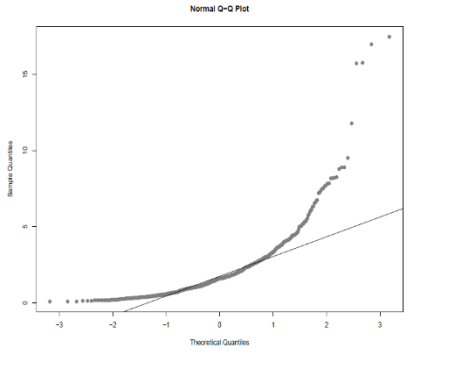
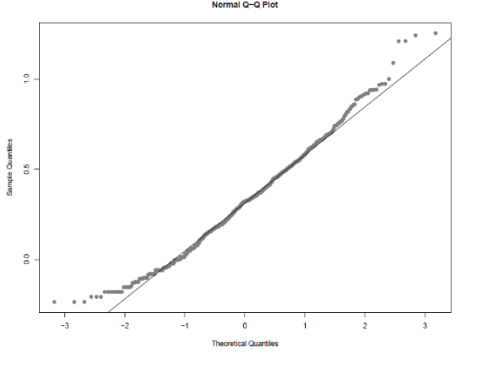
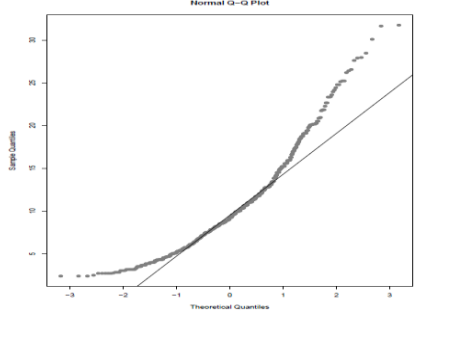
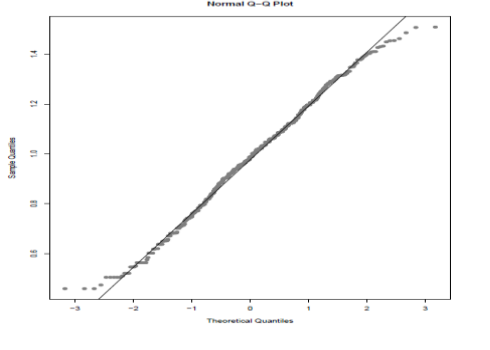
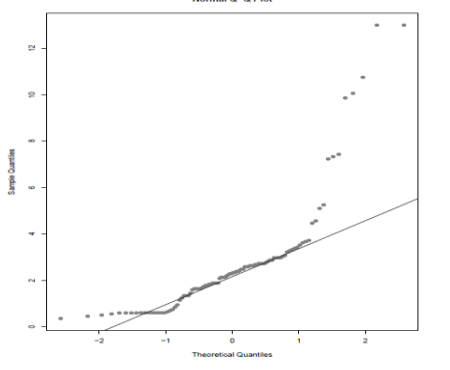
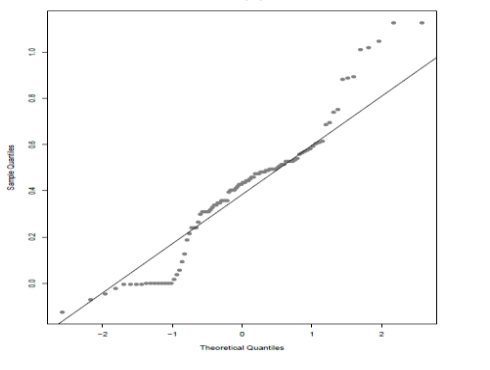
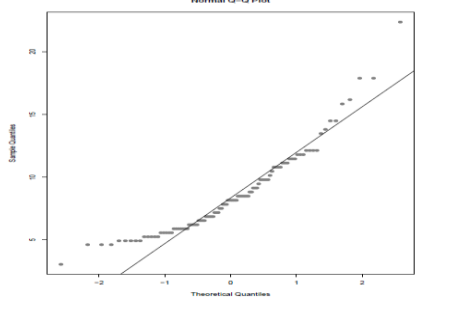
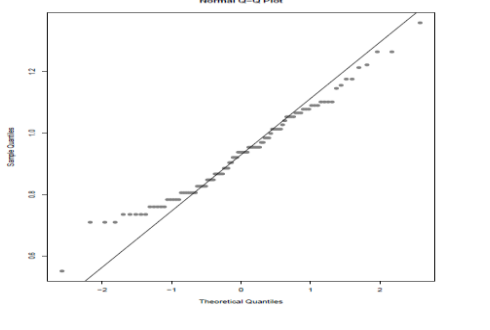
^b corresponden al muestreo de suelo puntual en el año 2016

significancia *p-value* < 0,05

Anexo 7. Histogramas de frecuencias de los elementos asimilables del suelo




Anexo 8. Gráficos cuantil-cuantil de los elementos asimilables del suelo


<p>Fósforo asimilable del suelo. Muestreo año 2015</p>		
<p>Potasio asimilable del suelo. Muestreo año 2015</p>		
<p>Fósforo asimilable del suelo. Muestreo año 2016</p>		
<p>Potasio asimilable del suelo. Muestreo año</p>		
	<p>Variable original</p>	<p>Variable Transformada</p>

Anexo 9. Correlación entre pares de valores a diferentes distancias

Fósforo asimilable del suelo. Muestreo año 2015




Potasio asimilable del suelo. Muestreo año 2015




Anexo 9. Continuación...

Fósforo asimilable del suelo. Muestreo año 2016



Potasio asimilable del suelo. Muestreo año 2016



Anexo 10. Modelos de semivariograma evaluados para fósforo asimilable.

<i>Modelo teórico¹</i>	<i>Método</i>	<i>SCE</i>	<i>RMSE</i>	<i>MSE</i>	<i>R</i>	<i>MSDR</i>
Exponencial	Wls 7	3,72e ⁻⁰⁷	0,241	0,058	0,52*	1,21
Exponencial	Ols	1,88e ⁻⁰⁴	0,237	0,056	0,53*	1,18
Exponencial **	Wls 1	1,28e⁻⁰¹	0,235	0,055	0,54*	1,14
Exponencial	Wls 2	3,10e ⁺⁰¹	0,236	0,056	0,53*	1,16
Esférico	Wls 7	3,96e ⁻⁰⁷	0,249	0,062	0,46*	1,31
Esférico	Ols	2,02e ⁻⁰⁴	0,245	0,060	0,48*	1,26
Esférico	Wls 1	1,30e ⁻⁰¹	0,237	0,056	0,53*	1,16
Esférico	Wls 2	2,69e ⁺⁰¹	0,237	0,056	0,53*	1,17
Gaussiano	Wls 7	4,10e ⁻⁰⁷	0,249	0,062	0,47*	1,30
Gaussiano	Ols	2,00e ⁻⁰⁴	0,245	0,060	0,48*	1,25
Gaussiano	Wls 1	1,31e ⁻⁰¹	0,239	0,057	0,53*	1,19
Gaussiano	Wls 2	3,16e ⁺⁰¹	0,242	0,059	0,51*	1,22
Lineal	Ols	1,97e ⁻⁰⁴	0,250	0,062	0,43*	1,31
Lineal	Wls 1	1,36e ⁻⁰¹	0,249	0,062	0,43*	1,30
Lineal	Wls 2	2,87e ⁺⁰¹	0,249	0,062	0,45*	1,29

** Modelo seleccionado

* correlación (Pearson) significativa $p\text{-value} < 0,05$

¹ para el caso del modelo lineal el ajuste por pesos ponderado (wls 7) no encontró convergencia y no aparece en la tabla.

Anexo 11. Modelos de semivariograma evaluados para potasio asimilable.

Modelo teórico ¹	Método	SCE	RMSE	MSPE	R	MSDR
Exponencial**	WLS 7	1,59e-07	0,153	0,023	0,71*	1,12
Exponencial	OLS	3,75e-05	0,155	0,024	0,70*	1,15
Exponencial	WLS 1	1,48e-02	0,154	0,024	0,71*	1,14
Exponencial	WLS 2	1,56e+01	0,157	0,024	0,71*	1,17
Esférico	WLS 7	1,57e-07	0,169	0,028	0,68*	1,38
Esférico	OLS	4,12e-05	0,167	0,028	0,69*	1,34
Esférico	WLS 1	1,74e-02	0,173	0,030	0,65*	1,46
Esférico	WLS 2	1,20e+01	0,167	0,028	0,69*	1,35
Gaussiano	OLS	3,93e-05	0,170	0,030	0,68*	1,34
Lineal	WLS 7	1,51e-07	0,180	0,030	0,65*	1,54
Lineal	OLS	4,12e-05	0,180	0,030	0,64*	1,50
Lineal	WLS 2	1,29e+01	0,180	0,030	0,64*	1,50


** **Modelo seleccionado,**

* Correlación (Pearson) significativa $p\text{-value} < 0,05$


¹ Para el caso del modelo lineal el ajuste por pesos ponderado (WLS 1, 2, 7) no encontraron convergencia y no aparece en la tabla.

Anexo 12. Mapas Varigráficos

Mapa variográfico del Fósforo asimilable del suelo



Mapa variográfico del Potasio asimilable del suelo



Anexo 13. Modelos de semivariograma evaluados para fósforo asimilable
(muestreo puntual en el año 2016).

<i>Modelo teórico**</i>	<i>Método</i>	<i>SCE</i>	<i>RMSE</i>	<i>MSPE</i>	<i>R</i>	<i>MSDR</i>
Wave**	OLS	0,0038	0,22	0,05	0,63*	0,91
Wave	WLS 2	0,341	0,23	0,06	0,60*	0,92

** Modelo seleccionado,

* correlación (Pearson) significativa p-value < 0,05

¹ de los diferentes modelos evaluados, solo los presentados en esta tabla se ajustaron para estas condiciones.

**Anexo 14. Modelos de semivariograma evaluados para potasio asimilable
(muestreo puntual en el año 2016).**

<i>Modelo teórico</i>	<i>Método</i>	<i>SCE</i>	<i>RMSE</i>	<i>MSPE</i>	<i>R</i>	<i>MSDR</i>
Exponencial	WLS 7	1,08E ⁻⁰⁶	0,141	0,020	0,31*	0,973
Exponencial	WLS 1	0,0032	0,143	0,020	0,28*	1,033
Exponencial	WLS 2	3,14	0,142	0,020	0,29*	1,010
Esférico	WLS 7	8,26E ⁻⁰⁷	0,139	0,019	0,34*	0,949
Esférico	WLS 1	0,0024	0,140	0,020	0,32*	0,989
Lineal	WLS 7	6,68E ⁻⁰⁷	0,139	0,019	0,35*	0,949
Lineal	OLS	1,03E ⁻⁰⁵	0,140	0,020	0,33*	0,990
Lineal	WLS 1	0,0021	0,140	0,020	0,32*	0,994
Lineal	WLS 2	1,56	0,140	0,020	0,33*	0,976
Wave**	WLS 1	0,00092	0,137	0,019	0,38*	0,954

** Modelo seleccionado,


* correlación (Pearson) significativa $p\text{-value} < 0,05$

¹ de los diferentes modelos, solo los presentados en esta tabla, se ajustaron para estas condiciones.


Anexo 15. Desviación estándar de las predicciones

Fósforo asimilable del suelo. Muestreo año 2015

Desviación estandar de la Predicción




Potasio asimilable del suelo. Muestreo año 2015




Anexo 15. Continuación...

Fósforo asimilable del suelo. Muestreo año 2016




Potasio asimilable del suelo. Muestreo año 2016




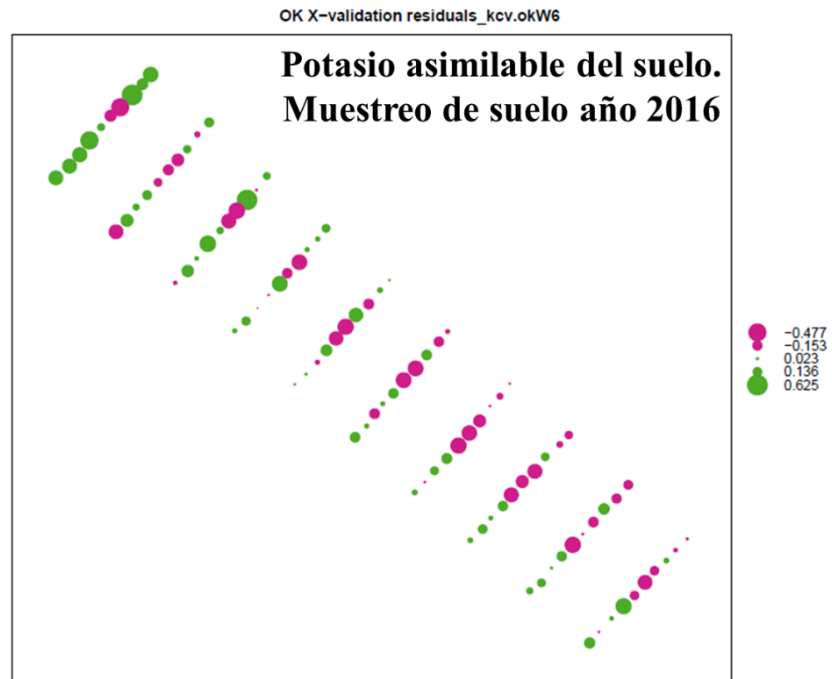
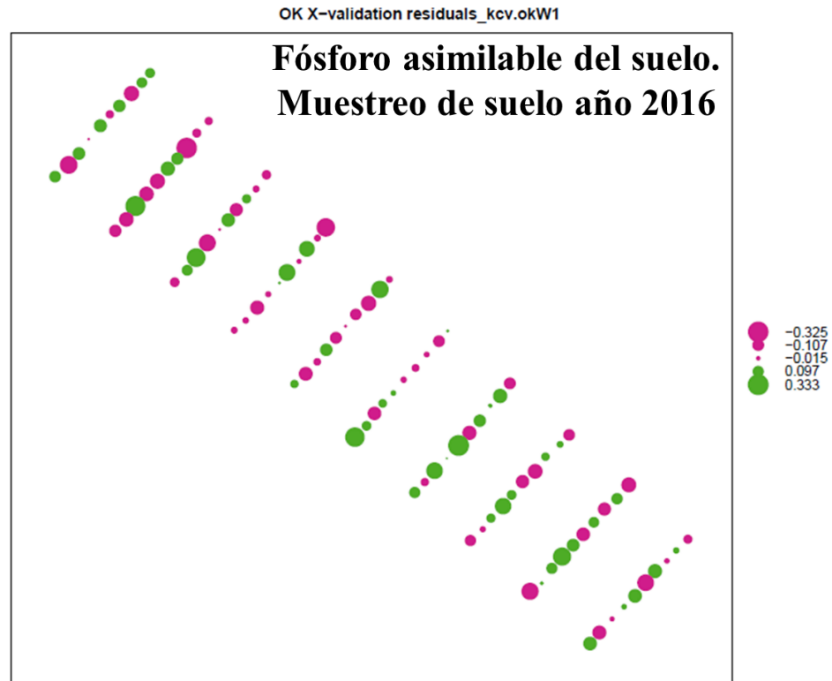
Anexo 16. Residuos en la validación cruzada

OK X-validation residuals_kcv.oKE1



OK X-validation residuals_kcv.oKE7





Anexo 17

Modelo de perjuicio para precios en CUP. Se utiliza como valor de cambio la relación de 120 CUP igual a 1 USD

Coefficientes del modelo de polinomio para perjuicios en CUP

	<i>Estimación</i>	<i>Error</i>	<i>valor T</i>	<i>Pr(> t)</i>	<i>Sig.</i>
Intercepto	1,070e ⁰³	4,108e ⁰²	2,604	0,00991	**
PERD_T	-2,146e ⁰²	4,116e ⁰¹	-5,213	4,68e ⁻⁰⁷	***
PERD_T ²	8,594e ⁰⁰	1,041e ⁰⁰	8,258	2,17e ⁻¹⁴	***
PRECIO	1,452e ⁻⁰²	1,105e ⁻⁰³	13,133	< 2e ⁻¹⁶	***

Significancia: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Error estándar residual: 216,1 con 196 grados de libertad

R² múltiple: 0,82, R² ajustado: 0,82

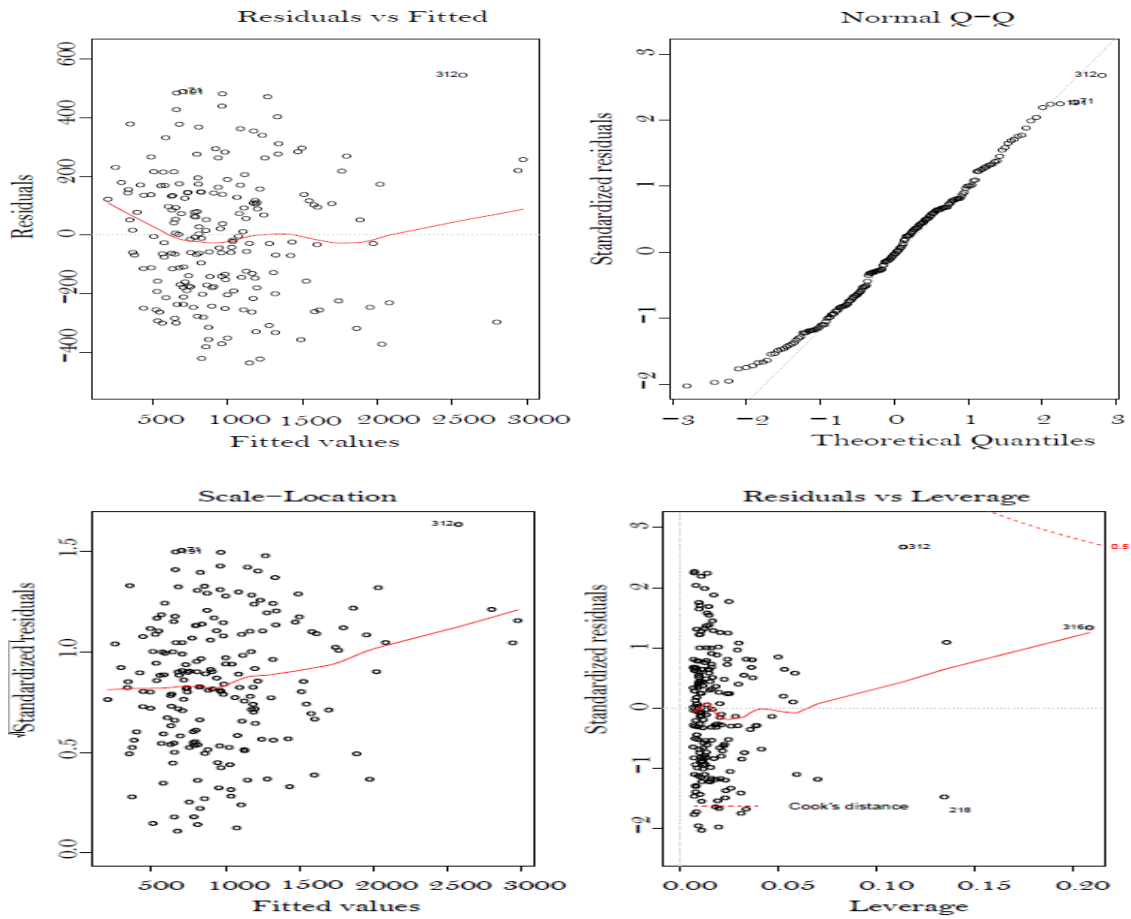
Estadígrafo F: 305 en 3 y *p-value*: < 2,2e⁻¹⁶

Validación de condiciones del modelo mediante pruebas estadísticas


<i>Prueba estadística</i>	<i>Método</i>	<i>Parámetros</i>
Prueba de normalidad	<i>Lilliefors</i>	D = 0,05; <i>p-value</i> = 0,24
Residuos estandarizados	<i>Breusch-Pagan</i>	BP = 7,68; df = 3; <i>p-value</i> = 0,053

Anexo 17. Continuación...

Validación de condiciones del modelo mediante elementos gráficos



Modelo y relación de valores observado vs predichos



Anexo 18.

Relación entre valores calculados por el modelo de perjuicios en USD multiplicado por 120 y los valores del modelo en CUP

