

Pontificia Universidad Católica del Ecuador

Facultad de Ingeniería

Maestría en Sistemas de Información mención Ciencia de Datos

Proyecto de titulación

Impacto de la producción agrícola en el cambio climático en

Suramérica: análisis comparativo entre 1990 y 2020

Autor: Carlos Miguel Aizaga Ruiz

Director: Ing. Rafael Melgarejo, PhD.

Quito, enero 2024

Índice

Agradecimientos	5
1. Introducción	6
2. Revisión de la literatura y marco teórico	9
2.1. La agricultura y las emisiones de GEI.....	9
2.2. Impacto de las emisiones de gases de efecto invernadero y el cambio climático.....	10
2.3. Antecedentes de la investigación	11
3. Metodología	13
3.1 Técnicas de procesamiento de los datos	14
3.2. Preparación de los datos.....	15
3.3. Matriz de operacionalización de variables	17
4. Resultados:	20
4.1 Análisis de correlaciones.....	20
4.2 Análisis del estudio de PCA	22
4.3 Análisis de clusterización	27
5. Conclusiones:.....	39
Bibliografía	40
Anexos	42

Índice de ilustraciones

Ilustración 1. Flujo CRISP-DM.....	15
Ilustración 2. Matriz de correlación de variables.....	21
Ilustración 3. Scree plot 1990	23
Ilustración 4. Scree plot 2020	23
Ilustración 5. Diagrama de dispersión PCA 1990	24
Ilustración 6. Diagrama de dispersión PCA 2020	24
Ilustración 7. Gráfico número óptimo de clusters N20 año 1990.....	28
Ilustración 8. Gráfico número óptimo de clusters CH4 año 1990.....	28
Ilustración 9. Gráfico de dispersión 3D Clusters obtenidos para N20, año 1990	29
Ilustración 10. Gráfico de dispersión 3D Clusters obtenidos para CH4, año 1990	30
Ilustración 11. Gráfico número óptimo de clusters N20 año 2020.....	31
Ilustración 12. Gráfico número óptimo de clusters CH4 año 2020.....	31
Ilustración 13. Gráfico de dispersión 3D Clusters obtenidos para N20, año 2020	32
Ilustración 14. Gráfico de dispersión 3D Clusters obtenidos para CH4, año 2020	33

Índice de tablas

Tabla 1. Matriz de operacionalización de variables:.....	17
Tabla 2. Loadings PCA 1990	25
Tabla 3. Loadings PCA 2020	26
Tabla 4. Resumen descripción de clusters obtenidos N20, año 1990	35
Tabla 5. Resumen descripción de clusters obtenidos CH4, año 1990	36
Tabla 6. Resumen descripción de clusters obtenidos N20, año 2020	37
Tabla 7. Resumen descripción de clusters obtenidos CH4, año 2020	38

Agradecimientos

A Dios, a mis padres, Luz y Miguel, por su constante apoyo durante todo este tiempo, a mi hermano Rey.

A mi director y tutor Rafael por su importante guía y dirección en la elaboración de este proyecto.

1. Introducción

El cambio climático ha emergido como uno de los desafíos más apremiantes del siglo XXI, afectando diversos aspectos de la vida en nuestro planeta. Con el paso de los años se han podido evidenciar estas afectaciones, en función de cambios dentro de diferentes variables que sirven como parámetro para hacer seguimiento al estatus del ambiente, variables como lo pueden ser la temperatura en tierra, las emisiones de gases de efecto invernadero, la frecuencia en cuanto a desastres naturales, entre otras.

Una de las actividades antropogénicas que afectan el cambio climático es la producción agrícola. Se estima que la población mundial incremente en al menos un 20% para el año 2050, lo que al ser analizado en conjunto con las tendencias actuales de crecimiento de cara a los niveles de ingreso y de consumo, la producción agrícola tendría que crecer en al menos un 60% para satisfacer el aumento de la demanda prevista de alimentos (Smith & Gregory, 2012).

Esta cifra de aumento necesario antes mencionado en la demanda mundial de alimentos va de la mano con el aumento poblacional y los cambios en los patrones alimentarios de la población, situación que viene ocurriendo en paralelo con el impacto continuo que genera el cambio climático sobre los sistemas alimentarios mundiales.

Por lo anteriormente mencionado, es necesario analizar la afectación que genera la producción agrícola sobre las variables que más afectan al cambio climático, siendo en este caso la emisión de gases de efecto invernadero, con especial énfasis en los gases CH₄ (metano) y N₂O (óxido de nitrógeno). Buscando comprender la relación que tienen los cultivos en términos de su rendimiento por hectárea cultivada (Yield) y producción total en los niveles de emisiones que generan.

De igual manera, al tratarse una situación de orden global, Suramérica no escapa a la misma, y muy a pesar de que se trate de una región, cuyos países no se encuentran entre los que más aportan en la emisión de gases de efecto invernadero comparativamente con respecto a aquellos que encabezan la lista, también tiene una cuota de participación dentro de estas emisiones causantes del cambio climático. Este trabajo se enfoca en la relación entre variables de tipo ambiental y climáticas, así como en la producción y el rendimiento de los cultivos: cebada, judías secas, maíz, mijo, avena, patatas, centeno, sorgo, soja, caña de azúcar y trigo en Suramérica, específicamente en 9 países de la región. Argentina, Bolivia, Brasil, Colombia, Chile, Ecuador, Perú, Paraguay y Uruguay, estudiando dos periodos diferenciados por tres décadas de diferencia, 1990 y 2020, centrándose específicamente en la identificación de aquellos cultivos que contribuyen de manera desproporcionada a las emisiones de gases de efecto invernadero (GHG), así como aquellos que contribuyen en una menor medida, tomando en consideración el

rendimiento (producción por hectárea) y la producción total (medida en toneladas) para cada uno de ellos, con la finalidad de dar con insights relacionados con respecto a los cultivos y sus respectivos impactos en cuanto a los desafíos ambientales que enfrentamos.

En esta investigación, se desea estimar y evaluar el impacto en termino de emisiones de los cultivos seleccionados dentro de los países de la región suramericana analizando en términos de su rendimiento, por lo que se busca responder a la pregunta: ¿Cuáles son las variables con mayor incidencia de cara a la producción alimentaria de la región durante el período de 1997 a 2020?, lo que a su vez busca la generar conciencia en función a los problemas que trae consigo el cambio climático sobre la sostenibilidad alimentaria.

Es importante destacar que a pesar de que cada uno de los países seleccionados son indiscutiblemente diferentes en función a sus características propias y particulares en términos de variables de tipo ambiental, es por ello por lo que a través de la de la aplicación de determinadas técnicas de ciencia de datos se buscará identificar aquellos atributos que impactan más dentro de la totalidad de variables relacionadas con el rendimiento de los alimentos y el cambio climático.

Ante esta problemática, que puede acarrear la actividad agrícola de cara al cambio climático, es menester preguntarse: ¿Cuál es el impacto de los cultivos seleccionados en términos de sus propias emisiones de gases y su contribución al calentamiento en Suramérica? Tratándose de preguntas que se plantean responder en un marco de tiempo de 30 años entendiendo 1990 como un periodo siete años antes del Protocolo de Kioto (11 de diciembre del año 1997) (United Nations Climate Change, n.d.) y 2020 como un año más reciente, cercano a los tiempos que corren.

El principal objetivo de esta investigación se encuentra en determinar cómo impacta cada uno de los cultivos seleccionados en términos de rendimiento en la emisión de gases que contribuyen al cambio climático, como ya se mencionó anteriormente comparado el año 1990 con él. Así como determinar el impacto de estos cultivos en términos de sus propias emisiones de gases y su contribución al calentamiento con respecto a cada país de Suramérica seleccionado a través de un algoritmo de clusterización aglomerativo., es decir mediante la agrupación de las observaciones de los países en conglomerados (clusters).

Para la consecución del objetivo anterior se plantea revisar información relacionada a trabajos científicos que traten sobre la relación entre cambio climático y el rendimiento y/o la producción de cultivos, particularmente con enfoque en herramientas y técnicas de ciencia de datos. A partir de esto, se plantea identificar todos aquellos patrones y correlaciones que existen en Suramérica en cuanto a la emisión de gases de efecto invernadero (CO₂, CH₄, and N₂O) y la temperatura en tierra sobre las categorías de

producción de alimentos en Suramérica, así como la relación existente entre rendimiento y emisiones de gases para cada uno de los cultivos

Para determinar el impacto de cada una de las variables seleccionadas, relacionadas con el cambio climático se procederá a aplicar la técnica de análisis de componentes principales con la finalidad de proveer un panorama general de la región suramericana y los respectivos países seleccionados, en función a sus atributos, reduciendo la dimensionalidad de cada una de las variables en el proceso.

Por último, se realizaría un análisis de los países suramericanos seleccionados respecto al impacto de cada cultivo en términos de su rendimiento y sus niveles de emisiones de gases de efecto invernadero, tanto para gases CH₄ (metano) como para gases N₂O (óxido de nitrógeno) a través de un algoritmo de clusterización jerárquica.

En la actualidad, el uso de técnicas de ciencia de datos (matemáticas, estadísticas y técnicas de la computación) ha revolucionado la forma en que se abordan problemas complejos caracterizados por tener grandes cantidades de variables asociadas, como sucede con el estudio del cambio climático (Faghmous & Kumar, 2014) la producción y el rendimiento de los alimentos, que se encuentra en función a variables de dimensiones económicas, ambientales, geográficas, entre muchas otras. Este enfoque no solo permite el análisis exhaustivo de conjuntos de datos extensos, sino que también posibilita la identificación de patrones, tendencias y factores determinantes.

Se aplicarán de técnicas de ciencia de datos, utilizando el lenguaje de programación Python, así como diferentes librerías relacionadas como Pandas, Matplotlib, NumPy, Scikit-Learn y Seaborn, a través del ambiente de trabajo Google Colab, lo que permite la capacidad de procesar los datos en cuestión, en un periodo de estudio que compara los años 1990 y 2020, en un primer lugar reduciendo la dimensionalidad de los datos, y en una segunda instancia, mediante un algoritmo de clusterización.

En este contexto se utilizarán como fuentes de datos estadísticas agregadas provenientes de diversos organismos multinacionales, como la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), el Banco Mundial (World Bank), el Fondo Monetario Internacional (IMF) y páginas de publicaciones como The Global Carbon Budget y Our World in Data, dado que son dentro de sus páginas web mantienen información de relevancia para el tema de estudio.

2. Revisión de la literatura y marco teórico

2.1. La agricultura y las emisiones de GEI

Aunque la agricultura no es la actividad antropogénica que más gases de efecto invernadero genera, es una actividad que tiene una tendencia claramente progresiva dado el crecimiento demográfico. En cuanto a este respecto, se puede notar la preeminencia de tres gases como consecuencia de actividades agrícolas, “El diez por ciento totales de las emisiones atribuibles a la agricultura se puede desglosar básicamente en las emisiones de óxido nitroso (N₂O), metano (CH₄) y dióxido de carbono CO₂” (Foodinsight, 2021). Las emisiones de N₂O incluyen el uso de fertilizantes, el drenaje y el riego. Mientras que el CO₂ se genera del encalado y la aplicación de urea, y el CH₄ de la quema de residuos de cultivos.

La agricultura libera cantidades importantes de CO₂, CH₄ y N₂O a la atmósfera. El CO₂ se libera en gran medida por descomposición microbiana o quema de hojarasca y suelo orgánico. El CH₄ se produce cuando los materiales orgánicos se descomponen. plantean en condiciones anóxicas, especialmente debido a procesos fermentativos. digestión por ganado rumiante, estiércol almacenado y arroz cultivado en condiciones de inundación. El N₂O es producido por transformación microbiana del N en suelos y estiércol, y es a menudo mejorado cuando el N disponible excede los requerimientos de la planta, especialmente en condiciones húmedas (Smith P, et al. (2008) citado por (Smith & Gregory, 2012).

Pese a que el sector agrícola es diverso, representa una pequeña proporción de la economía mundial, pero sigue siendo central para la vida de millones de personas. En el caso de América es importante resaltar la importancia de la agricultura, y que es que es gran ofertante a nivel mundial de commodities, concentrados en productos alimentarios. “Se espera que el sur de América del Sur desempeñe un papel cada vez más importante en la producción mundial de alimentos, pero el cambio climático podría amenazar seriamente” (Ferrero et al., 2017). Los principales cultivos en la región (arroz, avena, cebada, girasol, soja, sorgo, trigo, maíz).

Se estima que la población del mundo para el año 2050 se encuentre en 9 y 10 billones de personas, y mientras que se tienen que desarrollar nuevas técnicas de producción, de manejo de residuos y procesos de cambios de dieta, hace falta minimizar el impacto del cambio climático en la producción de alimentos (Cole et al., 2018).

Los efectos sobre el suministro de alimentos y la seguridad alimentaria podrían ser una de las consecuencias más importantes del cambio climático en virtud del gran grupo de personas que podría verse afectadas (Springmann et al., 2016) . Aunque se habla también que el cambio climático a pesar de

poder llegar a ser beneficioso en algunos cultivos, a largo plazo sería perjudicial para la agricultura en general, pudiendo impactar aún más en países en vías de desarrollo (Smith & Gregory, 2012). Esto implica que es apremiante la necesidad de reducir las emisiones para conseguir una agricultura sostenible (Smith & Gregory, 2012), ya que la seguridad alimentaria no sólo es amenazada por las altas temperaturas, sino por prácticas que deben ser optimizadas como el manejo integrado de plagas y enfermedades, manejo de cosecha y postcosecha, la innovación tecnológica y la conservación de la biodiversidad. “Las investigaciones han sugerido que la productividad en la agricultura disminuiría a medida que la temperatura aumenta debido al cambio climático. También las incidencias El número de plagas y otras enfermedades de los cultivos aumentará” (Rani & Reddy, 2023).

El cambio y la variabilidad climática pueden repercutir negativamente en la seguridad alimentaria, afectando diversas etapas de la cadena alimentaria, desde la producción hasta el consumo. Entre los factores más importantes estarían “los cambios en los patrones de temperatura y precipitaciones, aumento de la frecuencia e intensidad de fenómenos meteorológicos extremos, calentamiento y acidificación de los océanos y cambios en las vías de transporte de contaminantes, entre otros” (Tirado et al., 2010).

2.2. Impacto de las emisiones de gases de efecto invernadero y el cambio climático

“Son cinco los gases de origen humano que contribuyen en mayor medida -hasta un 95 % del total en conjunto- al aumento del calentamiento global” (Acciona, s.f.). El dióxido de carbono se genera esencialmente por el uso de combustibles, deforestación, producción de cementos y otros, y es responsable del 53% del nivel de calentamiento global. El metano se genera principalmente por la utilización de combustibles, residuos y la agricultura y tiene una incidencia del 15% en el calentamiento global. Los compuestos halogenados (**CFCs, HCFCs, HFCs, PFCs, SF₆ y NF₃**) son se emiten a partir de la producción química en sectores como medicina, metalurgia, electricidad y electrónica, refrigeración y climatización, e inciden en el 11 % del calentamiento global. El ozono troposférico es emitido en la quema de combustibles y tiene una incidencia del 11% en el calentamiento global. Y finalmente el óxido nitroso proviene especialmente del uso de fertilizantes, los combustibles, la producción química y el tratamiento de aguas residuales y contribuye en un 11% al total del calentamiento global (Acciona, s.f.) Un elemento preocupante es que la Organización de Naciones Unidas viene desde la última década del siglo XX realizando conferencias sobre el cambio climático, en las cuales muchos países acuden y firman acuerdos, sin embargo, estos esfuerzos no se han materializado de manera efectiva. “Las emisiones

globales de CO₂ alcanzaron un récord mundial en 2022, un año que terminará con unas emisiones de hasta 40.600 millones de toneladas de CO₂” y no se ven señales de que se produzca el ineludible y perentorio descenso para limitar el calentamiento global en 1,5 grados centígrados a final de siglo, según las cifras de Global Carbon Project (Epdata, 2023).

El cambio climático afecta a la seguridad alimentaria en todas sus dimensiones: acceso, disponibilidad, utilización y estabilidad. Este estudio muestra el impacto del aumento de la temperatura y del aumento de emisiones de CO₂ en el rendimiento (porcentual) de los principales cultivos arroz, trigo maíz y mostaza. A través de enfoques adecuados se podría mejorar la productividad, conseguir una mayor resiliencia y reducir de las emisiones de gases de efecto invernadero. Garantizar la seguridad alimentaria en el enfrentar el cambio climático será un desafío y, por lo tanto, sugiere prácticas agrícolas sostenibles junto con una agricultura climáticamente inteligente. (Rani & Reddy, 2023)

2.3. Antecedentes de la investigación

El primer antecedente investigativo relacionado con este estudio es el de Cai y otros autores 2013, en el artículo se hizo uso de un índice climático para medir la respuesta del rendimiento de los cultivos (*Using a Climate Index to Measure CropYield Response*). El objetivo de este estudio es comparar los efectos del cambio climático en el rendimiento de los cultivos en diferentes regiones. Dentro de la metodología se desarrolla un modelo de regresión de componentes principales (PCR) para estimar las relaciones históricas entre el clima y el rendimiento de los cultivos de maíz, soja, algodón y maní en varios estados del norte y sur de Estados Unidos. Los datos de proyección del cambio climático de tres modelos climáticos se aplican al modelo PCR estimado para pronosticar la respuesta del rendimiento de los cultivos. En lugar de utilizar directamente variables meteorológicas como variables predictivas, el modelo PCR utiliza índices meteorológicos transformados a partir de variables meteorológicas originales mediante el enfoque de Análisis de Componentes Principales (PCA). Se desarrolla un índice de impacto del cambio climático (CCII) para comparar los efectos del cambio climático en diferentes regiones.

Como principal conclusión se señala la contribución clave del estudio es identificar diferentes efectos del cambio climático en el rendimiento de los cultivos en diferentes estados de EE. UU. “Específicamente, que un clima más cálido en el futuro tendrá un impacto negativo para los condados del sur de EE. UU., mientras que tendrá un impacto insignificante para los condados del norte de EE. UU. en las próximas cuatro décadas” (Cai et al., 2011).

También se señala la investigación de Ferrero, Lima y González (2017) con el artículo titulado Estructura de producción de cultivos y estabilidad bajo el cambio climático en Sur América (*Crop production structure and stability under climate change*). El objetivo es analizar datos históricos a largo plazo para los principales cultivos (arroz, avena, cebada, girasol, soja, sorgo, trigo, maíz) a escala subnacional para examinar características comunes entre la dinámica del rendimiento de los cultivos, evaluando su estructura e implicaciones para la persistencia de ese cultivo; abordar cultivos complejos respuestas a cambios en las condiciones ambientales de crecimiento; e identificar puntos críticos de impacto climático que son cruciales para la adaptación y la mitigación. El enfoque metodológico fue basado en sistemas dinámicos para comprender los procesos detrás de las fluctuaciones anuales del rendimiento de los cultivos. Considerando variables como la tasa anual de aumento del rendimiento, el número de rezagos de tiempo, el máximo productivo, mediante el uso de una función de correlación de tasa parcial utilizando regresiones de mínimos cuadrados no lineales y la elección de modelos en base a su bondad de ajuste, su capacidad para describir la dinámica correcta y su oportunidad.

Las principales conclusiones se basan en demostrar la existencia de patrones generales para las principales dinámicas de rendimiento de cultivos en América del Sur basadas en las interacciones entre los límites internos (límites biofísicos por retroalimentación negativa de primer orden) y externa (clima y Emisión de CO₂). Se identificaron aquellos cultivos y regiones más vulnerables al cambio climático en América del Sur, estos resultados permiten señalar nuevas formas de mejorar el éxito de la autorregulación, maximizando la eficiencia de la producción de cultivos y reducir los impactos climáticos.

Como último trabajo previo a este estudio se señala el de Calvin y otros (2017) denominado Cuantificación de los impactos indirectos del clima en la agricultura: Una comparación entre métodos (*Quantifying indirect climate impacts on agriculture: A comparison between methods*). El objetivo de este trabajo es medir la importancia de los efectos de interacción a través de una comparación entre métodos entre modelos de proceso, modelos estadísticos y modelo de evaluación integrada (integrated assessment model - IAM). Buscando medir los impactos del cambio climático en los rendimientos estimados mediante modelos de cultivos estadísticos y basados en procesos con los resultados de IAM que capturan retroalimentaciones e interacciones importantes, como cambios tecnológicos, sustitución de insumos, y cambio de cultivos.

Se encontró que los impactos en los rendimientos de los cultivos varían ampliamente entre estos enfoques de modelado. Los Impactos en el rendimiento generados por los (IAM) or agro-economic model. IAM son entre un 20% y un 40% más altos que los impactos en el rendimiento generados por cultivos estadísticos o modelos basados en procesos, con efectos climáticos indirectos que ajustan los

rendimientos entre -12% y +15% (por ejemplo, sustitución y cambio de cultivos). Los efectos restantes se deben al cambio tecnológico (Calvin & Fisher-Vanden, 2017).

3. Metodología

En cuanto al diseño sistemático del estudio para garantizar resultados válidos y fiables que respondan a las metas y objetivos de la investigación se plantea una metodología en la cual se enmarca el estudio en un tipo documental, con enfoque cuantitativo, mediante el método deductivo, de diseño no experimental y con alcance correlacional.

“La investigación documental es un proceso basado en la búsqueda, recuperación, análisis, crítica e interpretación de datos secundarios; es decir, los obtenidos y registrados por otros investigadores en fuentes documentales: impresas, audiovisuales o electrónicas” (Arias, 2012). En este caso se hace una indagación sobre las estadísticas relacionadas con variables de tipo ambiental, publicadas en las páginas webs de organizaciones mundiales, tales como el Banco Mundial o la FAO, entre otros.

El enfoque es cuantitativo “Este enfoque se fundamenta en la medición de las características de los fenómenos, (...). Los datos que se producen y desean interpretar son cuantificables, por lo tanto, se pueden contar y medir” (Monroy Mejía & Nava Sanchezllanes, 2018). En el estudio se medirán variables de tipo ambiental de tipo numérico continuo, tales como la producción y rendimiento de cultivo agrícolas alimentos y emisiones de gases de efecto invernadero de cada uno de ellos.

El razonamiento es deductivo que “es el procedimiento racional que va delo general a lo particular. Posee la característica de que las conclusiones de la deducción son verdaderas, si las premisas de las que se originan también lo son” (Gómez, 2012). Esta investigación hace uso premisas generales, de las cuales se pretender obtener conclusiones particulares, mediante el uso de metodologías relacionadas con la ciencia de datos para realizar el recuento, ordenación y categorización de los datos logrados por las observaciones, en función de construir tablas, gráficos y/o modelos que permitan simplificar la dificultad de los datos que intervienen.

Asimismo, es un estudio no experimental que son “Estudios que se realizan sin la manipulación deliberada de variables y en los que sólo se observan los fenómenos en su ambiente natural para después analizarlos” (Hernández Sampieri et al., 2014, pág. 149). El presente estudio analiza datos recopilados por entes a nivel mundial, por lo cual es una investigación Ex Post Facto.

Se emplea un estudio correlacional, “Este tipo de estudios tiene como finalidad conocer la relación o grado de asociación que exista entre dos o más conceptos, categorías o variables en un contexto en particular”

(Hernández Sampieri et al., 2014, pág. 93); se enmarca aquí, dado que se quiere ver en qué medida la producción de los cultivos seleccionados impactan en variables relacionadas en el cambio climático, en términos de sus correspondientes emisiones de gases de efecto invernadero.

3.1 Técnicas de procesamiento de los datos

El coeficiente de correlación de Pearson revela cuán asociadas se encuentran dos variables entre sí, con valores entre -1 y 1. Mientras más próximo se encuentre a -1, se refiere a una correlación negativa perfecta. Y de manera opuesta, mientras más próximo se encuentre a 1, se refiere a una correlación positiva perfecta. Por otro lado, los valores cercanos a 0 (cero) implica que no hay asociación entre las variables estudiadas.

La fórmula para el coeficiente es:

$$r = \frac{N \sum xy - \sum x \sum y}{\sqrt{[N \sum x^2 - (\sum x)^2][N \sum y^2 - (\sum y)^2]}}$$

Donde:

r = coeficiente de correlación de Pearson.

S_{xy} = sumatoria de los productos de ambas variables.

S_x = sumatoria de los valores de la variable independiente.

S_y = sumatoria de los valores de la variable dependiente.

S_x² = sumatoria de los valores al cuadrado de la variable independiente.

S_y² = sumatoria de los valores al cuadrado de la variable dependiente.

Además, se realiza El Análisis de Componentes Principales (PCA) cuyo propósito es encontrar la variabilidad en un conjunto de datos y reducir las dimensiones del conjunto de datos. igualmente se realiza una clusterización que es útil para agrupar elementos similares en un conjunto, es decir, divide una base de datos en grupos diferentes para categorizarlos, conformando grupos homogéneos entre sí y heterogéneos con los demás grupos.

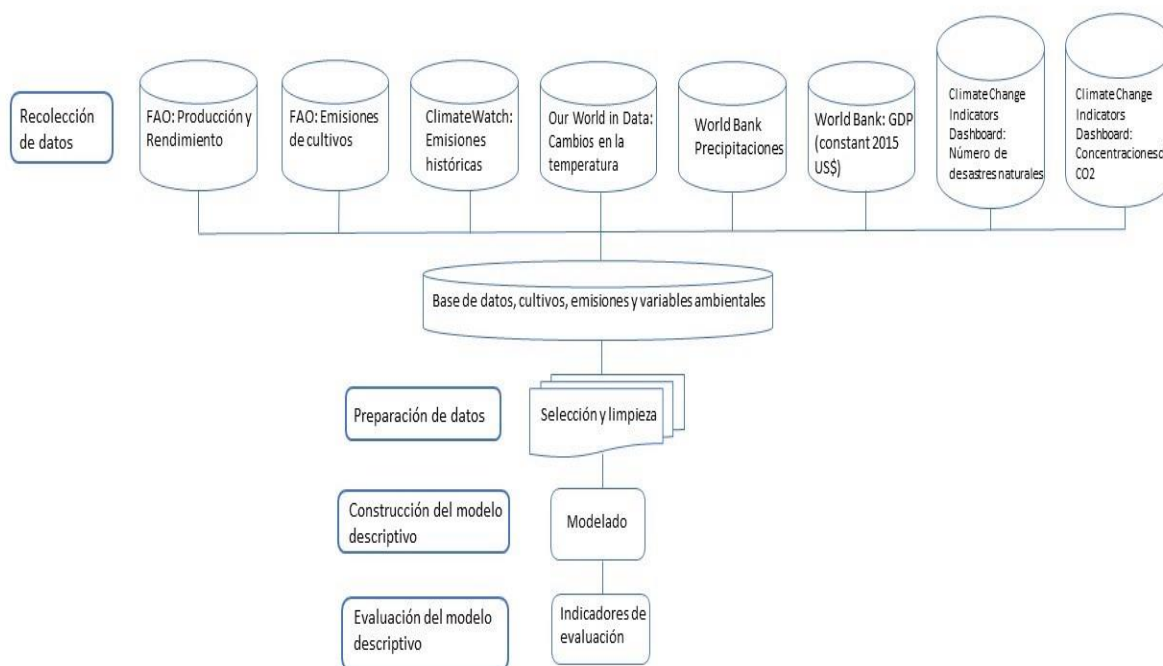
La investigación estudia la emisión de gases de efecto invernadero, CH₄ y N₂O de los cultivos: cebada, judías secas, maíz, mijo, avena, patatas, centeno, sorgo, soja, caña de azúcar y trigo en 9 países de la región de Suramérica, Argentina, Bolivia, Brasil, Colombia, Chile, Ecuador, Perú, Paraguay y Uruguay, estudiando dos periodos particulares, diferenciados por tres décadas que son el 1990 y 2020, para ello, se emplean técnicas de minería de datos, Principal component análisis (PCA) y Clusterización Aglomerativa con el fin de generar información que permita determinar el impacto de los cultivos

seleccionados y su aporte en función a sus niveles de emisiones de gases de efecto invernadero. (CO₂, CH₄, and N₂O).

Se hace uso de la técnica de PCA (Principal Component Analysis – Análisis de Componentes Principales) con la finalidad de conseguir patrones en los países de la región, en términos de los cambios en la temperatura de los países seleccionados. Posteriormente se hace uso de una técnica de clusterización para agrupar aquellas observaciones de los países seleccionadas con respecto a tres variables principales, la producción en toneladas, el rendimiento del cultivo, y las emisiones de gases correspondientes, tanto para el gas de tipo CH₄ como para el N₂O.

En este caso, se aplica la metodología CRISP-DM, en una primera etapa haciendo un entendimiento de la problemática en cuanto al impacto que genera las variables relacionadas al cambio climático en los países seleccionados, como se puede observar en el siguiente grafico:

Ilustración 1. Flujo CRISP-DM



3.2. Preparación de los datos

Se recolectaron datos procedentes de la sección de estadísticas de La Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), lo cual garantiza confiabilidad, validez, objetividad en sus datos. Hablar de que las páginas son bonitas

El primer dataset usado para la obtención de datos para el estudio de clusterización se obtuvo de la FAO (FAOSTAT, Emissions from Crops, n.d.), con una dimensión de 17289 registros y 36 variables, dentro de este dataset se seleccionaron los países antes mencionados correspondientes a la región de Suramérica, así como los cultivos seleccionados, esto con la finalidad de obtener la data relacionada con los gases N₂O y CH₄, es también importante destacar que toma en cuenta el sector “Total, incluyendo LULUCF” -Land use, land-use change and forestry- Uso de la tierra, cambio de uso de la tierra y selvicultura, lo cual es ventajoso porque proporciona una visión global de las emisiones y absorciones de gases de efecto invernadero, incorporando el impacto de los cambios en el uso de la tierra. Este enfoque permite una evaluación holística, se ajusta a las normas internacionales de información, tiene en cuenta los distintos potenciales de calentamiento global de los diferentes gases y reconoce las implicaciones medioambientales más amplias de las actividades humanas.

Dentro de este primer dataset, es eliminada la clase ‘arroz’ dentro de la variable ‘Item’ que indica el nombre del cultivo, esto debido a que dentro de las mediciones contaminantes de arroz, la FAO maneja una sección aparte para lo que tiene que ver con el cultivo de arroz denominada “Rice cultivation” y que no será tomada en consideración para la realización de este estudio.

Para el apartado de rendimiento y producción de cada uno de los cultivos escogidos se tomaron las variables rendimiento (Yield) medida en 100 g/h y producción (Production) medida en toneladas, de igual manera obtenido del sitio web de la FAO (FAOSTAT, Crops and livestock products, n.d.), obteniendo un total de 2458207 de registros y 6 variables

A través de la fusión de los mencionados datasets y posterior a las transformaciones necesarias para conseguir las variables de interés relacionadas con cada país, el tipo de cultivo, el tipo de unidad, así como el tipo de gas emitido, y los valores respectivos para producción y rendimiento, que posterior a ser filtrado por los dos años que interesan a este estudio, se obtuvo un dataset con 84 registros y 8 variables para cada uno de los años.

Para la conformación del dataset usado en el estudio exploratorio a través de PCA, el primer dataset, relacionado con las emisiones históricas por país fue obtenido de la página web de ClimateWatch (ClimateWatch, n.d.) con un total original de 1881 registros y 37 variables.

Se utilizó también un dataset proveniente de la página web de Our World in Data (Our World in Data, n.d.) que contiene los cambios anuales de temperatura producto de los diferentes gases de efecto invernadero, obteniendo un total de 50598 registros y 79 variables. De igual manera, fue utilizado el dataset de la FAO relacionado con producción y rendimiento antes mencionado y utilizado en el análisis anterior con un total de 2458207 de registros y 6 variables. A fines de complementar aún más el análisis de tipo ambiental,

también fue añadido un dataset relacionados con las precipitaciones en cada uno de los países obtenido de la página web del World Bank (World Bank, n.d.), para un total de 16758 registros y 6 variables. De igual manera se añadió la variable de Producto Interno Bruto (medido en dólares constantes del 2015) de igual manera de la página web del World Bank (World Bank, n.d.), con un total de 266 registros y 67 variables. De la misma manera también se agregó un dataset relacionado con el tipo y total de desastres naturales dentro de los países proveniente de la página web del Climate Change Dashboard del Fondo Monetario Internacional (IMF Climate Change Indicators Dashboard, n.d.) con un total de 970 registros. Por último, también de la misma web (IMF Climate Change Indicators Dashboard, n.d.), se obtuvo data relacionada con las concentraciones de CO2 en la atmosfera con un total de 279 registros y 10 variables. La totalidad de estas bases de datos fueron previamente filtradas para los años de interés, 1990 y 2020, y para los países seleccionados, también fue necesario homogenizar las columnas de año y país, con la finalidad de que sirvieran como columnas comunes para conseguir la unión de todos los datasets antes mencionados, posteriormente a estos pasos, se obtuvo un dataset unificado con 17 variables y 9 observaciones para cada año.

3.3. Matriz de operacionalización de variables

La descripción de cada una de estas variables se puede observar en la siguiente matriz de operacionalización:

Tabla 1. Matriz de operacionalización de variables:

Dimensión	Variable	Definición Operacional	Indicador	Fuente del Ítem
Demográfica	Population	Población de cada país o región.	Tamaño de la población, cantidad de habitantes	Our World in Data
Ambiental	All GHG	Las emisiones de gases de efecto invernadero incluyen dióxido de carbono, metano y óxido nitroso de todas las fuentes, incluida la agricultura y el cambio de uso de la tierra. Se miden en equivalentes de dióxido de carbono	Millones de toneladas métricas de dióxido de carbono equivalente (mtCO ₂ e)	Climatewatch

CH4	Representa las emisiones de metano, un potente gas de efecto invernadero. El metano se libera a la atmósfera a partir de diversas fuentes, como la digestión del ganado, los arrozales y la producción y el transporte de carbón, petróleo y gas natural.	Millones de toneladas métricas de dióxido de carbono equivalente (mtco ₂ e)	Climatewatch
CO2	Representa las emisiones de dióxido de carbono, que es el gas de efecto invernadero más común. El CO ₂ se libera a la atmósfera a través de actividades como la quema de combustibles fósiles (carbón, petróleo y gas natural), la deforestación y otros procesos industriales.	Millones de toneladas métricas de dióxido de carbono equivalente (mtco ₂ e)	Climatewatch
F-Gas	Representa probablemente las emisiones de gases fluorados, que incluyen los hidrofluorocarbonos (HFC), los perfluorocarbonos (PFC), el hexafluoruro de azufre (SF ₆) y el trifluoruro de nitrógeno (NF ₃). Los gases fluorados, aunque presentes en concentraciones más bajas, pueden tener un potencial de calentamiento global mucho mayor que el CO ₂ .	Millones de toneladas métricas de dióxido de carbono equivalente (mtco ₂ e)	Climatewatch
N2O	Representa las emisiones de óxido nitroso, otro potente gas de efecto invernadero. El óxido nitroso se libera a la atmósfera a partir de actividades agrícolas e industriales, así como durante la combustión de combustibles fósiles.	Millones de toneladas métricas de dióxido de carbono equivalente (mtco ₂ e)	Climatewatch
Temperature_change_from_ch4	Cambio en la temperatura media de la superficie global (en ° C) causado por las emisiones de metano. Esto mide la contribución de cada país a la temperatura media de la superficie global (GMST) aumentando de sus emisiones acumulativas de metano, utilizando el enfoque del potencial de calentamiento global (GWP*).	Grados Celsius, cambio climático, emisiones de CH4	Our World in Data based on Jones et al. (2023)

Temperature_change_from_co2	Cambio en la temperatura media de la superficie global (en ° C) causado por las emisiones de CO2. Esto mide la contribución de cada país a la temperatura media global de la superficie (GMST) de sus emisiones acumulativas de dióxido de carbono, utilizando el enfoque del potencial de calentamiento global (GWP*).	Grados Celsius, cambio climático, emisiones de CO2	Our World in Data based on Jones et al. (2023)
Temperature_change_from_ghg	Cambio en la temperatura media de la superficie global (en ° C) causado por las emisiones de gases de efecto invernadero. Esto mide la contribución de cada país a la temperatura media global de la superficie (GMST) de sus emisiones acumulativas de dióxido de carbono, metano y óxido nitroso, utilizando el enfoque del potencial de calentamiento global (GWP*).	Grados Celsius, cambio climático, gases de efecto invernadero	Our World in Data based on Jones et al. (2023)
Temperature_change_from_n2o	Cambio en la temperatura media de la superficie global (en ° C) causado por emisiones de óxido nitroso. Esto mide la contribución de cada país a la temperatura media global de la superficie (GMST) de sus emisiones acumulativas de óxido nitroso, utilizando el enfoque del potencial de calentamiento global (GWP*).	Grados Celsius, cambio climático, Emisiones de N2O	Our World in Data based on Jones et al. (2023)
Average precipitation in depth (mm per year)	La precipitación media es la media a largo plazo en profundidad (en el espacio y en el tiempo) de la precipitación anual en el país. La precipitación se define como cualquier tipo de agua que cae de las nubes en forma líquida o sólida.	Milímetros de agua	World Bank
Number of Disasters: TOTAL	Evolución del número de desastres naturales relacionadas con el clima.	Número de desastres naturales	International Monetary Fund
Carbon Dioxide Concentrations (Annual mean)	Concentraciones mensuales de dióxido de carbono en la atmósfera, variación porcentual interanual	Porcentaje	International Monetary Fund

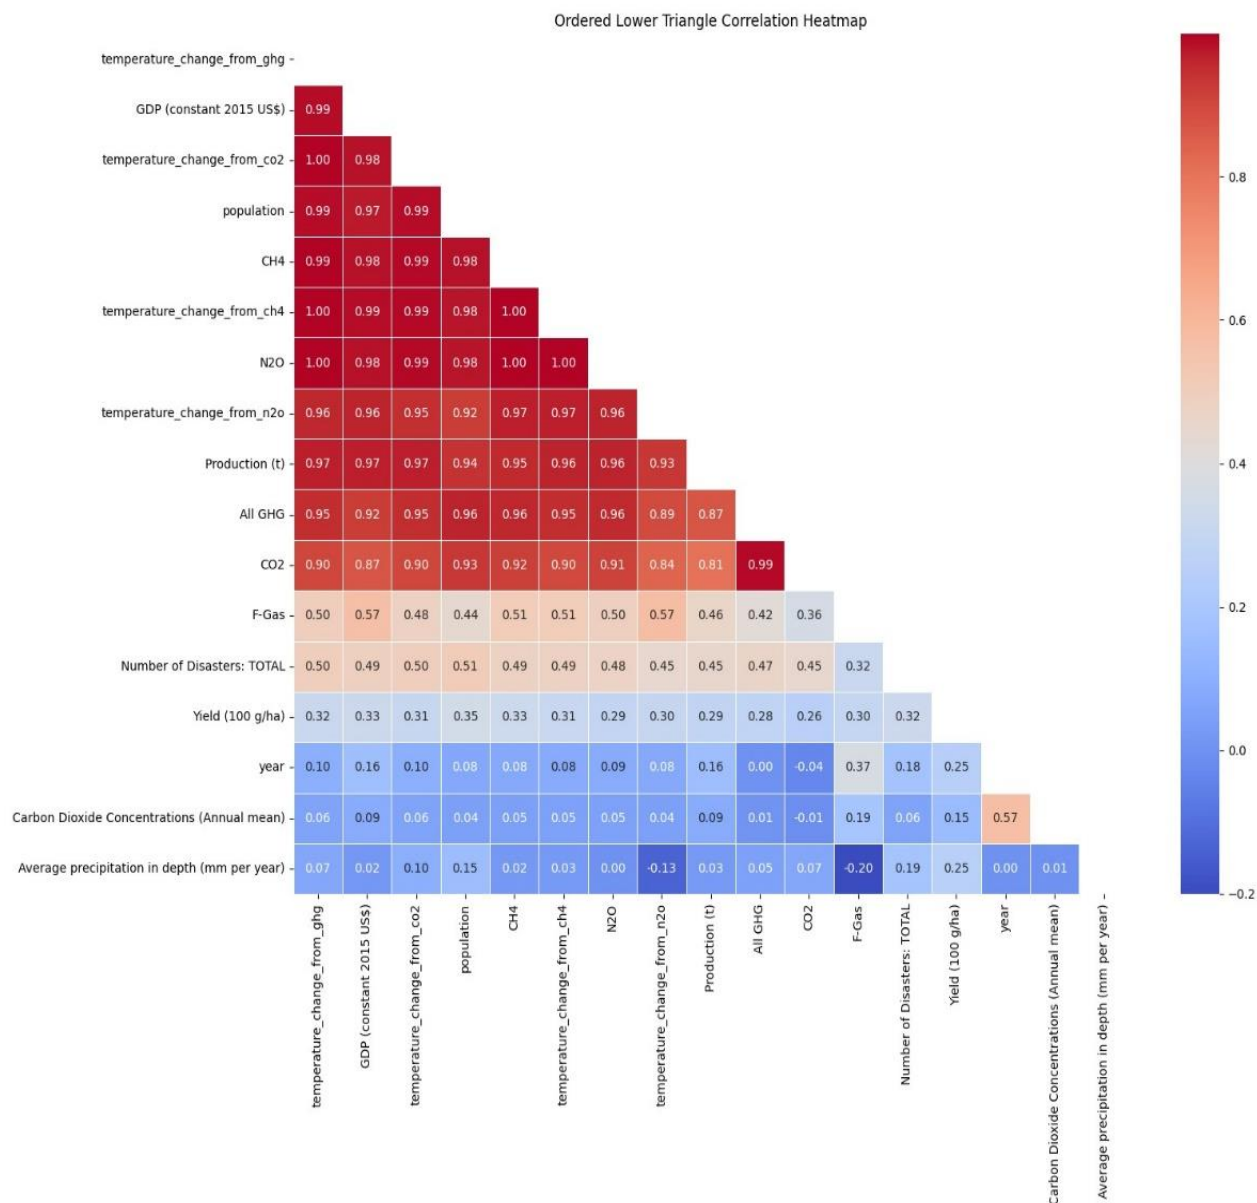
Económica	GDP (constant 2015 US\$)	El PIB a los precios del comprador es la suma de valor agregado bruto por todos los productores residentes en la economía más cualquier impuesto de productos y menos los subsidios no incluidos en el valor de los productos. Se calcula sin hacer deducciones para la depreciación de activos fabricados o para el agotamiento y la degradación de los recursos naturales. Los datos están en los precios constantes de 2015, expresados en dólares estadounidenses. Las cifras de dólar para el PIB se convierten de monedas nacionales utilizando tipos de cambio oficiales de 2015. Para algunos países donde el tipo de cambio oficial no refleja la tasa aplicada efectivamente a las transacciones reales de divisas, se utiliza un factor de conversión alternativo.	Millones de dolares, Producto Interno Bruto, desempeño económico	World Bank
	Producción (tons)	Producción: cultivos y productos ganaderos, medidos en toneladas	Producción industrial, medida en toneladas	Food and Agriculture Organization of the United Nations
	Yield (100 g/ha)	Cantidad de cultivos y productos ganaderos producidos por hectárea, medida en gramos.	Rendimiento industrial, medida en gramos	Food and Agriculture Organization of the United Nations

4. Resultados:

4.1 Análisis de correlaciones

La matriz de correlación fue construida en base a todos los años del dataset considerado para el posterior análisis de componente principales, correspondiendo al periodo que va de 1990 a 2020.

Ilustración 2. Matriz de correlación de variables



En ella se pueden ver relaciones entre variables que son de interés para el estudio, uno de los principales descubrimientos de interés son las correlaciones de las variables correspondientes a las emisiones de gases (con excepción del F-Gas) con los cambios en las temperaturas producto de estos mismos gases, coeficientes que en su totalidad son superiores al 0.80 según el coeficiente de correlación de Pearson. Esto no indica otra cosa sino el hecho de que, ante una emisión mayor de gases, son mayores las

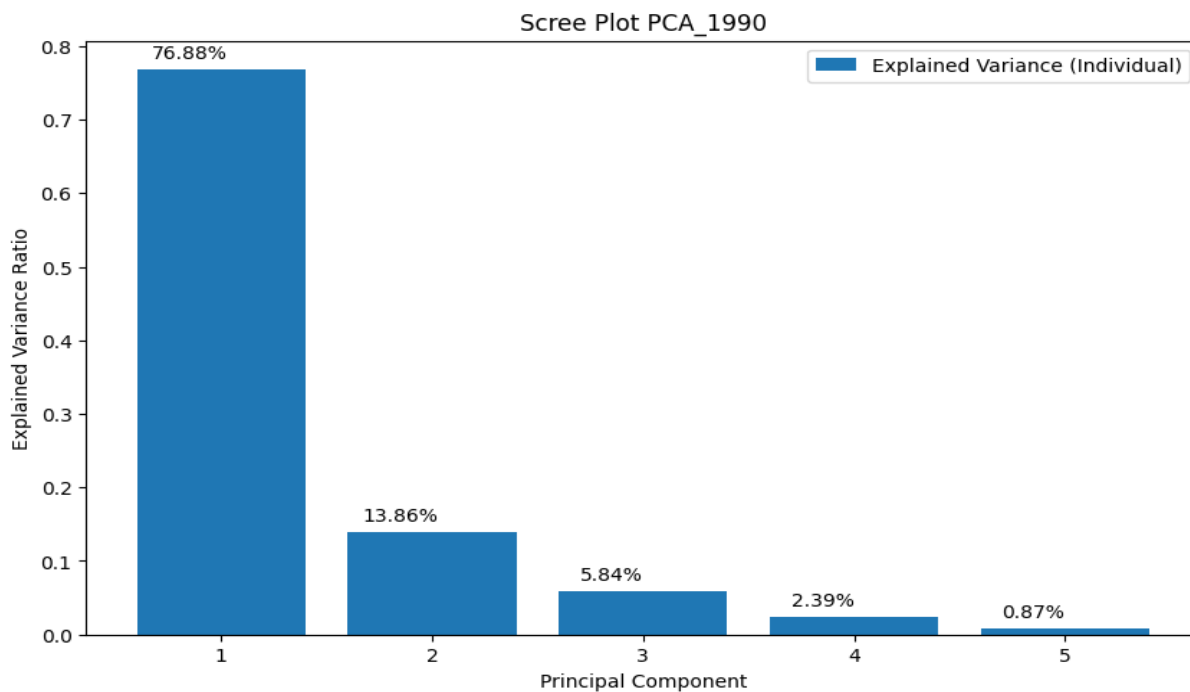
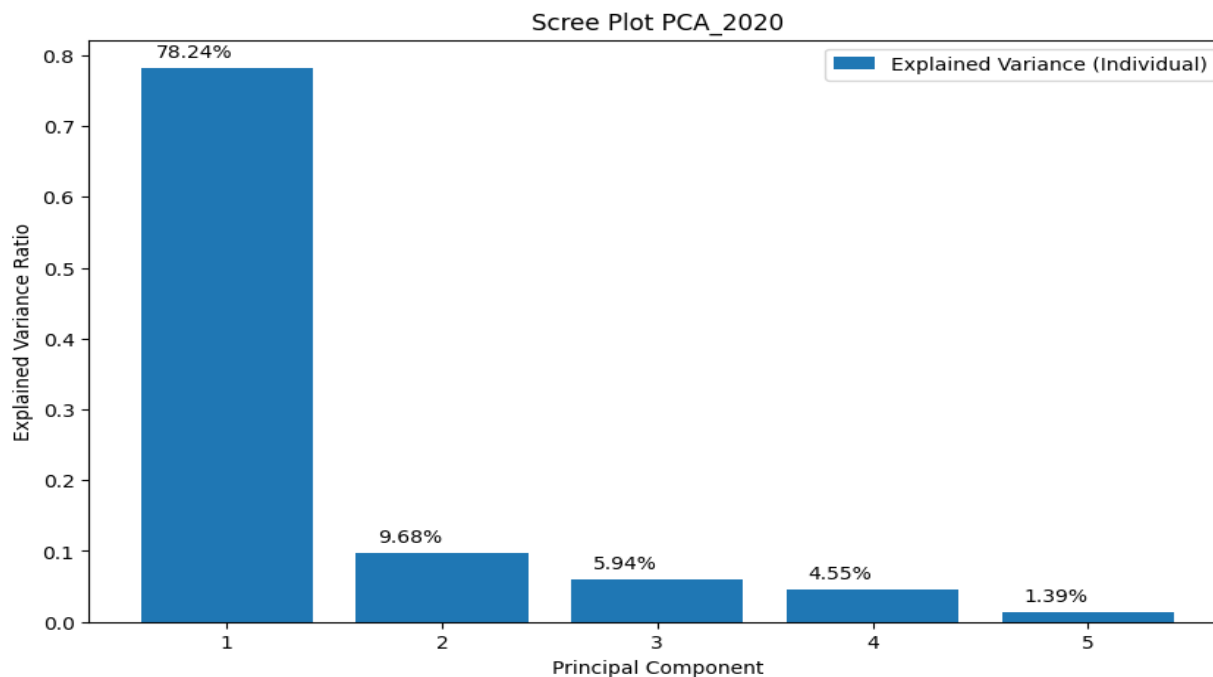
variaciones en la temperatura, producto de estos mismos, es importante destacar que correlación no indica causación.

Por otro lado, otro descubrimiento que puede parecer preocupante es el hecho de la correlación que mantiene el Producto Interno Bruto, con muchas de las variables de tipo ambiental, relacionadas tanto con la emisión de gases como los cambios de temperaturas producto de los gases, con correlaciones que superan el 0.85 en todos los casos. Sumado a esto, también se puede observar la interacción del Producto Interno Bruto con las otras variables de tipo económico, como la producción o el rendimiento, donde se ve que a pesar de que el Producto interno Bruto tiene una relación positiva directa y fuerte con la producción del 0.96, no sucede de igual manera en el rendimiento de los cultivos (yieedd) , donde se nota mucho más débil con tan solo un 0.33. Adicionalmente, también se puede ver que en el caso del rendimiento las correlaciones son mucho más débiles con respecto a las demás variables (a excepción de la producción), dando muestra que el rendimiento de los cultivos puede depender de otras variables que vayan más allá de las consideradas en este estudio.

4.2 Análisis del estudio de PCA

Tratándose de un estudio comparativo, se elaboró un análisis de componentes principales para los dos años seleccionados, 1990 y 2020. En un primer lugar se hizo una separación entre la data numérica y la no numérica a fines de la aplicación del algoritmo de análisis de componentes principales. Posteriormente se hizo una normalización de la data numérica.

A continuación, se mostrarán cada uno de los gráficos de Scree, mostrando las varianzas explicadas de cada uno:

Ilustración 3. Scree plot 1990**Ilustración 4. Scree plot 2020**

A partir de la visualización en el diagrama de Scree, se puede ver buena parte de la varianza explicada se haya en el primer componente principal, con 76,88% para 1990 y con 78,24% para 2020, mientras que en el caso del segundo con solo 13,86% para 1990 y 9.68% para 2020. A través de este primer análisis se

puede observar que más del 85% de la varianza de los datos se encuentra en solo dos componentes para ambos, y siendo poco lo que puede aportar un tercer componente para ambos periodos.

En base a lo anterior, y a través de la aplicación del algoritmo de PCA con 2 componentes principales se obtiene un gráfico de tipo (MDS Escalamiento multidimensional) que muestra la posición y la distancia entra cada uno de los países de acuerdo con los componentes principales recién creados.

Ilustración 5. Diagrama de dispersión PCA 1990

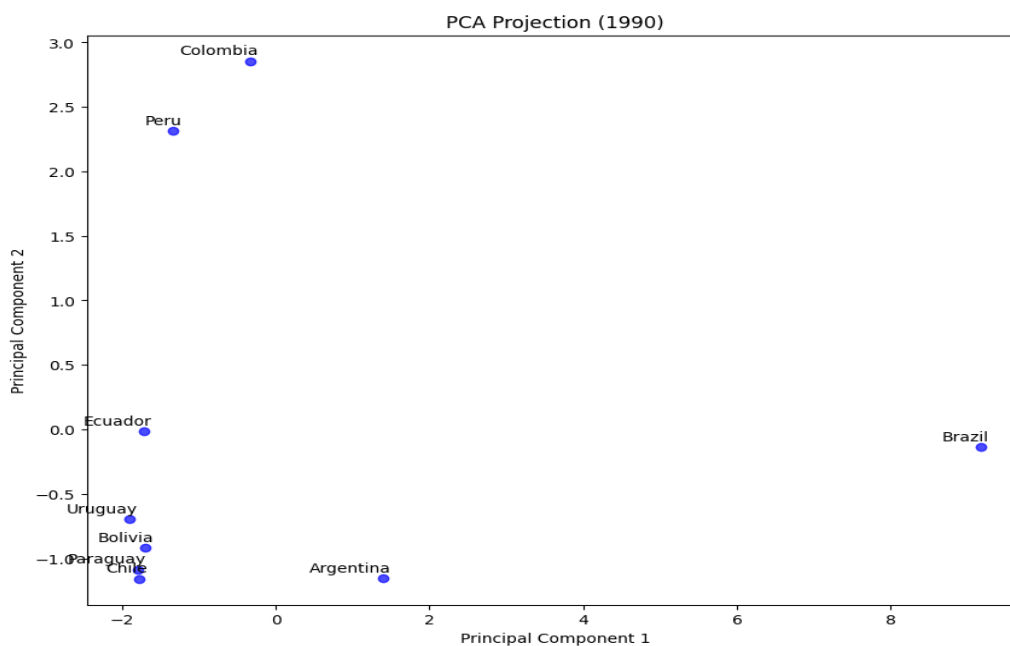
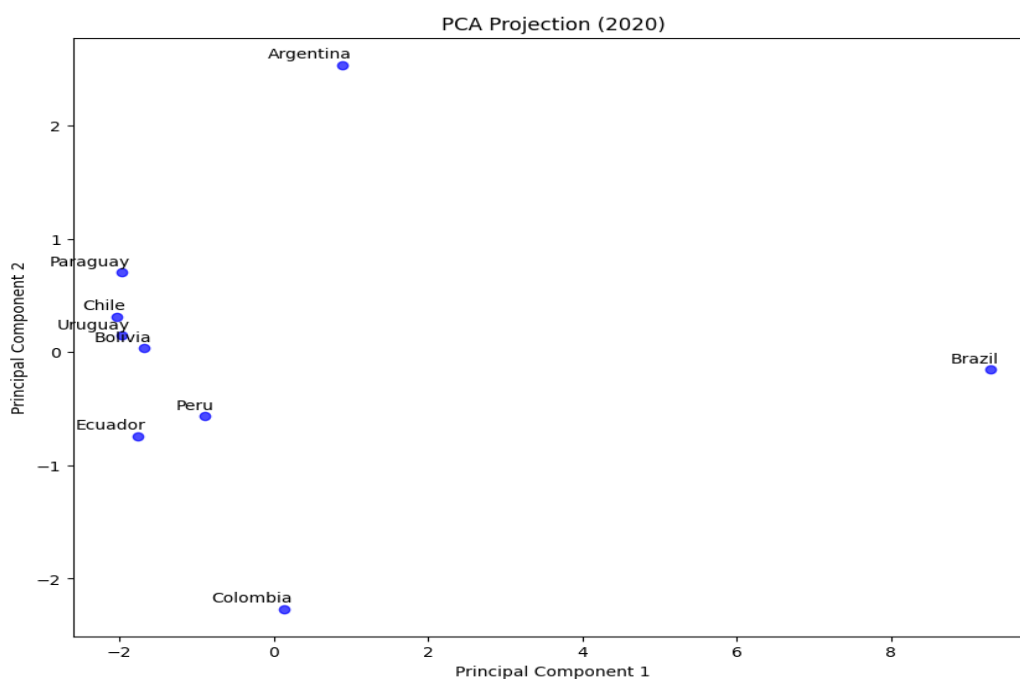


Ilustración 6. Diagrama de dispersión PCA 2020



A través de la aplicación de este algoritmo se obtuvieron un conjunto de loadings, correspondientes a cada una de las variables seleccionadas y su relación con cada uno de los componentes principales.

Tabla 2. Loadings PCA 1990

Variables	PC1	PC2
All GHG	1.049021	0.009975
CH4	1.057244	-0.02673
CO2	1.037771	0.024783
F-Gas	1.038178	-0.13798
N2O	1.055729	-0.05582
GDP (constant 2015 US\$)	1.057752	-0.02529
population	1.0473	0.106301
temperature_change_from_ch4	1.057274	-0.07417
temperature_change_from_co2	1.051987	0.070818
temperature_change_from_ghg	1.057215	0.033718
temperature_change_from_n2o	0.882178	-0.25452
Yield (100 g/ha)	0.178431	0.830338
Production (t)	1.04815	0.000418
Average precipitation in depth (mm per year)	0.033277	0.83024
Number of Disasters: TOTAL	0.137141	0.920552
Carbon Dioxide Concentrations (Annual mean)		0

Para las variables relacionadas con PC1, una buena aproximación es considerar todas aquellas que con loadings positivos (mayores que 0.5), pudiéndose ver que en este grupo se encuentran todas las variables relacionadas con gases de efecto invernadero (GHG, CH4, CO2, F-Gas, N2O, temperatura_change_from_ch4, temperatura_change_from_co2, temperatura_change_from_ghg) teniendo loadings significativos en PC1. Pudiendo sugerir que PC1 está asociado principalmente con la variabilidad en las emisiones de gases de efecto invernadero y el cambio de temperatura. Sumado a esto el Producto Interno Bruto, la producción y población también tienen loadings positivos, indicando una asociación positiva con las emisiones de gases de efecto invernadero y el cambio de temperatura.

Mientras que para el caso de PC2, entre aquellas variables con loadings positivos (mayores que 0.5), se encuentran el rendimiento, la precipitación promedio y el número de desastres naturales. Pudiendo sugerir que PC2 se encuentra asociado a estas variables. También se observa, algunas variables con

loadings negativos (menores que -0.5), como en el caso de las emisiones de N2O y el cambio de temperatura producto de ghg, teniendo loadings negativos significativos.

En resumen, se puede señalar que en el caso de PC1 se puede interpretar que parece estar relacionado con las emisiones de gases de efecto invernadero, el crecimiento económico y la población, mientras que PC2 está relacionado con la producción agrícola, la precipitación y los desastres, basándonos en la magnitud y signo de los loadings.

Tabla 3. Loadings PCA 2020

Variables	PC1	PC2
All GHG	1.05848	0.01931
CH4	1.056178	0.057129
CO2	1.054927	-0.03778
F-Gas	0.471099	0.610868
N2O	1.05158	0.078566
GDP (constant 2015 US\$)	1.049392	0.056114
population	1.053198	-0.08616
temperature_change_from_ch4	1.057831	0.024619
temperature_change_from_co2	1.055118	-0.00518
temperature_change_from_ghg	1.056406	0.021147
temperature_change_from_n2o	1.039384	-0.01982
Yield (100 g/ha)	0.430075	0.065907
Production (t)	1.041296	0.055999
Average precipitation in depth (mm per year)	0.092015	-0.98468
Number of Disasters: TOTAL	0.780598	-0.50965
Carbon Dioxide Concentrations (Annual mean)	0	0

Para el caso de 2020, se sigue la misma lógica, buscando para PC1 todas aquellas variables con loadings positivos (mayores que 0.5), incluyéndose en este grupo todas las variables relacionadas con gases de efecto invernadero (GHG, CH4, CO2, N2O, temperatura_change_from_ch4, temperature_change_from_co2, temperatura_change_from_ghg) con loadings positivos significativos en PC1, de igual manera, sugiriendo que PC1 está asociado principalmente con la variabilidad en las emisiones de gases de efecto invernadero y el cambio de temperatura. De igual manera GDP (constant 2015 US\$) y población también tienen loadings positivos, indicando una asociación positiva con las emisiones de gases de efecto invernadero y el cambio de temperatura.

En el caso de PC2, se pueden observar aquellas variables con loadings positivos (mayores que 0.5): donde el número de desastres naturales tiene un loading positivo significativo en PC2, indicando que PC2 está asociado con la variabilidad en el número total de desastres, ocurriendo de igual manera para la precipitación promedio con un loading negativo significativo en PC2, sugiriendo una asociación inversa con el número total de desastres.

Las diferencias en las tablas de loadings entre 1990 y 2020 revelan cambios significativos en las contribuciones de las variables a los componentes principales. Ambos años mantienen loadings positivos en PC1 para las emisiones de gases de efecto invernadero, con una disminución relativa en la influencia de F-Gas en 2020. Las variables relacionadas con el cambio de temperatura tienen impactos consistentes en PC1, aunque con ligeras variaciones. En PC2, la producción agrícola y el número total de desastres mantienen loadings positivos en ambos periodos, pero hay cambios en la relación de estas variables con PC2 cotejando ambos periodos. La precipitación muestra un cambio destacado en 2020 con un loading negativo más pronunciado en PC2, indicando una contribución más fuerte a la variabilidad. Todas estas discrepancias sugieren transformaciones en las condiciones ambientales, económicas y sociales, en el transcurso de entre un año y otro, no obstante, es importante destacar el papel que juegan las variables de tipo ambiental bajo un contexto general.

4.3 Análisis de clusterización

Lo que se desea ver a través de este análisis de clusterización, es buscar conseguir algún patrón común en los datos, considerando, como ya se mencionó anteriormente el cultivo, su nivel de producción y su nivel de rendimiento, en términos de gases N₂O y CH₄.

Para conseguir un número óptimo de k, se puede usar la métrica de la silueta, esta métrica indica que tan bien están definidos se encuentran los clusters en función a los puntos de datos dentro de cada conglomerado, proporcionando información sobre qué tan relativamente son similares entre sí a la vez en cuan son distintos de los puntos de otros conglomerados.

En una primera instancia se analiza lo que corresponde al año 1990. En los siguientes gráficos se muestran dos gráficos de líneas, uno para cada tipo de emisión, que sirven para determinar un valor óptimo de k, entendido como el número de clusters a considerar.

Ilustración 7. Gráfico número óptimo de clusters N2O año 1990


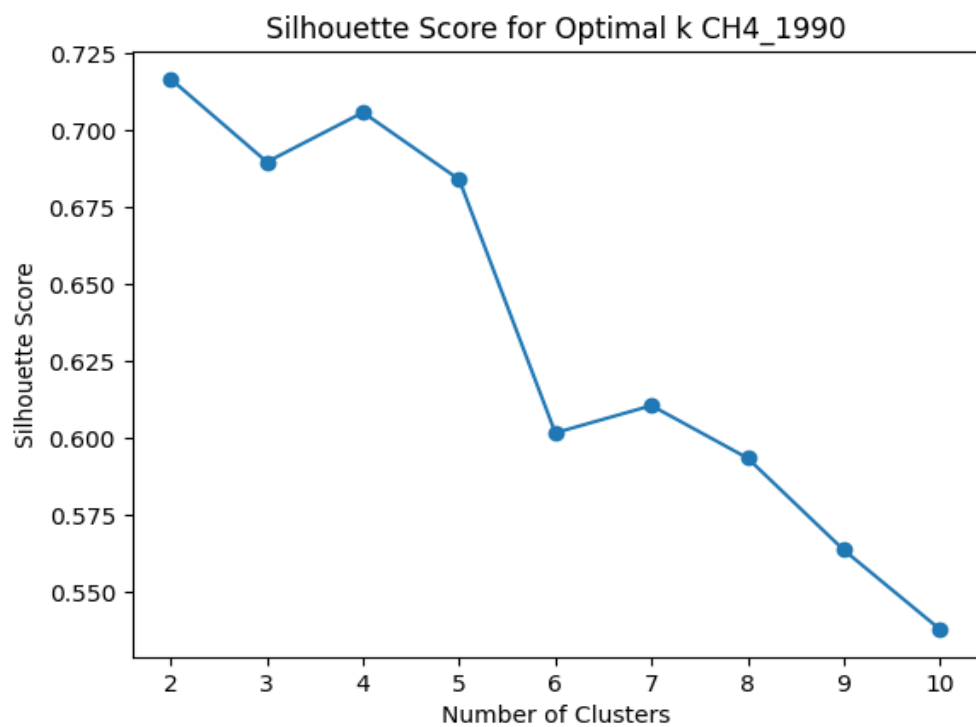


Ilustración 8. Gráfico número óptimo de clusters CH4 año 1990



A partir de estos resultados se proceden a crear los diferentes clusters a partir del k óptimo obtenido en los gráficos anteriores, por lo que en este caso se usa el valor de 4.

Ilustración 9. Gráfico de dispersión 3D Clusters obtenidos para N2O, año 1990


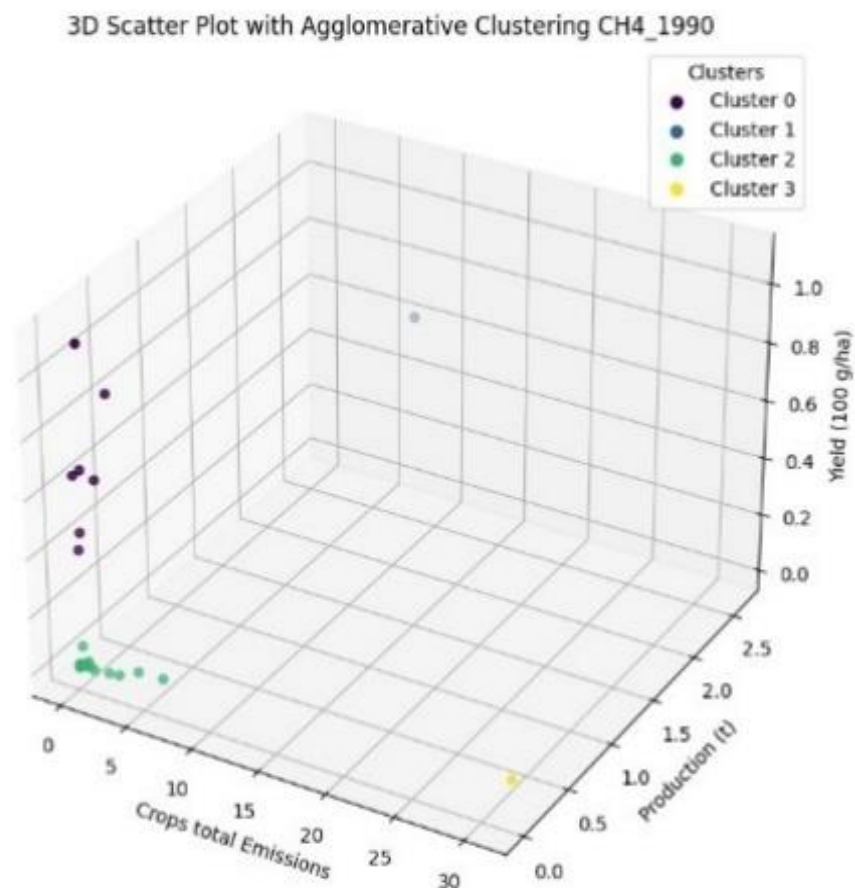


Ilustración 10. Gráfico de dispersión 3D Clusters obtenidos para CH4, año 1990



Descripción de clusters obtenidos: Emisiones de N2O para 1990:

En el Cluster 0, Brasil y Argentina destacan en las emisiones de N2O, siendo el maíz y la soja los principales cultivos contribuyentes. Brasil lidera en emisiones de maíz, mientras que Argentina sobresale en soja y trigo. El Cluster 1 muestra emisiones más bajas, con Argentina, Bolivia y Chile participando en cultivos como cebada, frijoles y maíz. El Cluster 2 resalta emisiones de azúcar de Argentina, Bolivia y Paraguay, mientras que en el Cluster 3, Brasil es líder en emisiones de caña de azúcar (Ver Tabla 1).

Descripción de clusters obtenidos: Emisiones de CH4 para 1990:

En el Cluster 0 de 1990, se observa que Argentina, Bolivia, Colombia, Ecuador, Paraguay y Uruguay están involucrados en la producción de caña de azúcar, siendo Colombia el principal contribuyente. Mientras tanto, en el Cluster 1, Brasil destaca significativamente con altas emisiones de caña de azúcar. En el Cluster 2, Argentina lidera las emisiones de maíz y trigo, seguida por Chile, Colombia y Ecuador. El Cluster 3 resalta las emisiones de maíz y trigo en Brasil, con cifras notables (Ver Tabla 2).

Posteriormente, se realiza el análisis correspondiente para el año 2020, de la misma manera como con el año anterior, mostrando los los dos gráficos de líneas que sirven para aproximar el valor óptimo de k.

Ilustración 11. Gráfico número óptimo de clusters N2O año 2020

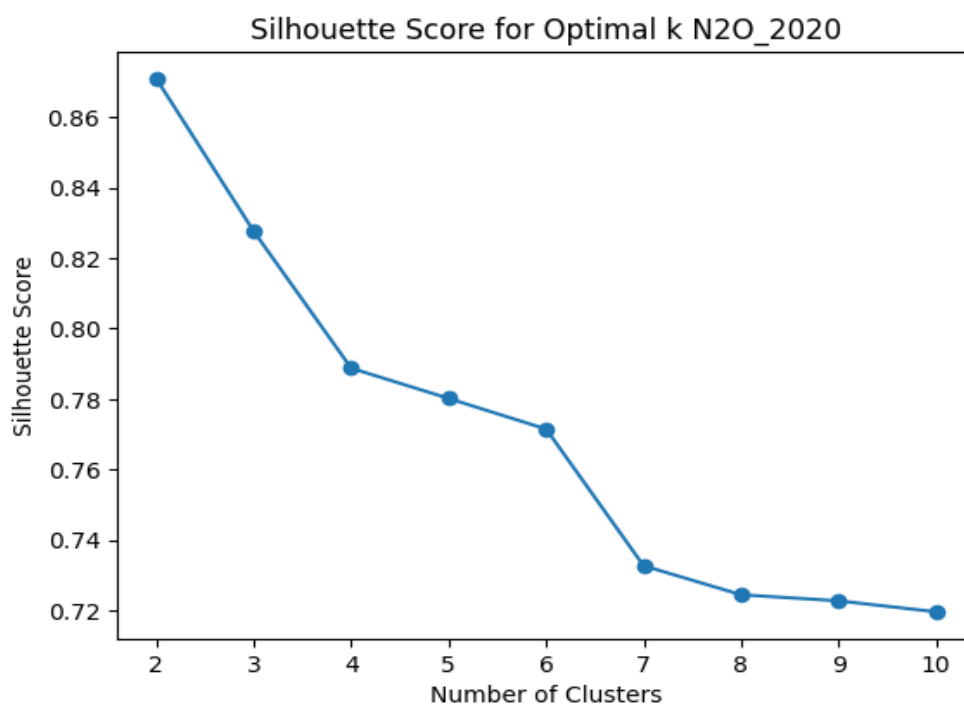
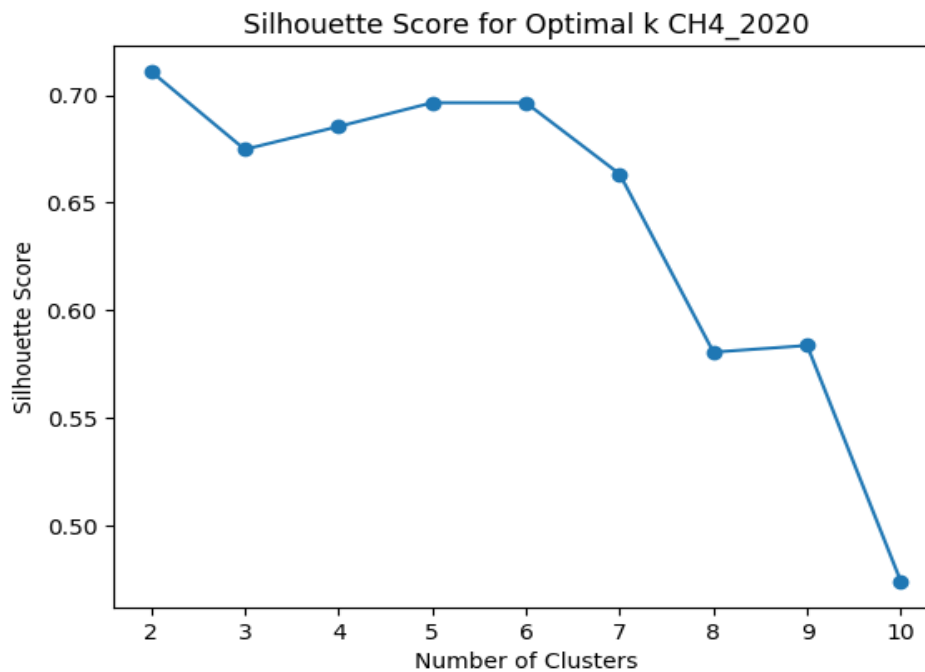


Ilustración 12. Gráfico número óptimo de clusters CH4 año 2020



A partir de estos resultados se obtienen los diferentes clusters a partir del k óptimo, que, para términos de comparación, con el año anterior, se usa de igual manera 4, como k óptimo, obteniendo los siguientes clusters.

Ilustración 13. Gráfico de dispersión 3D Clusters obtenidos para N20, año 2020





Ilustración 14. Gráfico de dispersión 3D Clusters obtenidos para CH4, año 2020



Descripción de clusters obtenidos: Emisiones de N2O para 2020:

En el Cluster 2 de 2020, Brasil continúa liderando las emisiones de maíz y soja, con cifras significativamente incrementadas desde 1990. En el Cluster 0, Argentina destaca en la producción de maíz y trigo, mientras que en el Cluster 1, Argentina, Colombia y Brasil lideran las emisiones de caña de azúcar, siendo Argentina la principal contribuyente. En el Cluster 3, Brasil sigue siendo el líder en emisiones de caña de azúcar, con valores más altos que en 1990 (Ver Tabla 3).

Descripción de clusters obtenidos: Emisiones de CH4 para 2020:

En el Cluster 0 de 2020, se mantiene la tendencia de emisiones de caña de azúcar, con Argentina, Bolivia, Colombia, Ecuador, Paraguay y Uruguay, siendo Colombia el principal emisor. El Cluster 1 muestra una gran contribución de Brasil en emisiones de caña de azúcar, con valores notoriamente más altos que en 1990. En el Cluster 2, Argentina lidera las emisiones de maíz y trigo, seguida por Colombia, Brasil y Chile. Por último, el Cluster 3 destaca nuevamente las emisiones significativas de maíz y trigo en Brasil (Ver Tabla 4).

A través de los resultados obtenidos se puede observar que Brasil y Argentina son actores clave en las emisiones de gases de efecto invernadero (N₂O y CH₄) relacionadas con la agricultura, siendo la producción de caña de azúcar, maíz y soja las principales fuentes de estas emisiones, esto siendo también producto de su extensión geográfica. Otro insight de interés es ver la característica de rendimiento de los cultivos, donde la caña de azúcar resalta entre los demás cultivos en cuanto a este respecto.

Por último, se observa un aumento considerable en los niveles de emisiones en el año 2020 en comparación con 1990, lo que resalta la necesidad de considerar estas emisiones en pro de mitigar el impacto ambiental, poniendo especial atención a cultivos como el maíz y los granos de soja.

A través de la información antes conseguida se puede conseguir una lista con las observaciones que corresponden a cada uno de los clusters para cada año, en este apartado, de manera resumida, solo incluyendo los promedios de las variables consideradas, una visualización más detallada se puede ver en las tablas contenidas en los anexos.

Tabla 4. Resumen descripción de clusters obtenidos N₂O, año 1990

Nro. de Cluster	Area	Items	Crops total Emissions	Production (t)	Yield (100 g/ha)
Cluster 0	Argentina	Soya beans,Wheat	2.8658	10377850	20256.5
	Brazil	Maize (corn),Soya beans	5.3639	20622787	18028.5
Cluster 1	Argentina	Barley, Beans, dry, Maize (corn), Millet, Oats, Potatoes, Rye, Sorghum	0.229563	1299752	41768.88
	Bolivia	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat	0.031322	158833.9	17705.56
	Brazil	Barley, Beans, dry, Oats, Potatoes, Rye, Sorghum, Wheat	0.304514	1162554	29863.43
	Chile	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Soya beans, Wheat	0.0881	470053.5	45239
	Colombia	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Sorghum, Soya beans, Wheat	0.091475	628273.8	35087.25
	Ecuador	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat	0.027078	122590.9	18196.78

	Paraguay	Beans, dry, Maize (corn), Potatoes, Sorghum, Soya beans, Wheat	0.114033	422767.5	24564.17
	Peru	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat	0.0323	223662.2	20081.78
	Uruguay	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Sorghum, Soya beans, Wheat	0.028825	123515.9	25443.63
Cluster					
2	Argentina	Sugar cane	0.0116	15700000	614123
	Bolivia (Plurinational State of)	Sugar cane	0.0038	3880186	463754
	Colombia	Sugar cane	0.0145	27790736	873006
	Ecuador	Sugar cane	0.0039	5720897	671703
	Paraguay	Sugar cane	0.0027	2449329	408222
	Peru	Sugar cane	0.0028	6700000	1089431
	Uruguay	Sugar cane	0.0005	682800	665757
Cluster					
3	Brazil	Sugar cane	0.1944	2.63E+08	614788

Nota: Ver anexo A

Tabla 5. Resumen descripción de clusters obtenidos CH4, año 1990

Nro. de Cluster	Area	Item	Crops total Emissions	Production (t)	Yield
					(100 g/ha)
Cluster 0	Argentina	Sugar cane	0.4487	15700000	614123
	Bolivia (Plurinational State of)	Sugar cane	0.1468	3880186	463754
	Colombia	Sugar cane	0.5587	27790736	873006
	Ecuador	Sugar cane	0.1495	5720897	671703
	Paraguay	Sugar cane	0.1053	2449329	408222
	Peru	Sugar cane	0.1079	6700000	1089431
	Uruguay	Sugar cane	0.018	682800	665757
Cluster 1	Brazil	Sugar cane	7.4984	2.63E+08	614788
Cluster 2	Argentina	Maize (corn), Wheat	4.9724	7727850	26777.5

	Bolivia	Maize (corn), Wheat	0.36225	222716	11569
	Brazil	Wheat	2.8955	3093791	11540
	Chile	Maize (corn), Wheat	0.45125	1270682	55438
	Colombia	Maize (corn), Wheat	1.1604	659050	16490.5
	Ecuador	Maize (corn), Wheat	0.61285	247653	9284.5
	Paraguay	Maize (corn), Wheat	0.34235	339678	19281
	Peru	Maize (corn), Wheat	0.48075	360151	15189.5
	Uruguay	Maize (corn), Wheat	0.20365	264856.5	18510
Cluster 3	Brazil	Maize (corn)	30.7646	21347770	18735

Nota: Ver anexo B

Tabla 6. Resumen descripción de clusters obtenidos N20, año 2020

Nro. de Cluster		Items	Crops total Emissions	Production (t)	Yield (100 g/ha)
Cluster 0	Argentina	Barley, Beans, dry, Maize (corn), Millet, Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat	2.84341	13762696	64973.3
		Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat			
	Bolivia	Sorghum, Soya beans, Wheat	0.1605	734068.6	22045.78
		Barley, Beans, dry, Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat			
	Brazil	Wheat	0.477329	2459284	66212.86
		Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat			
	Chile	Soya beans, Wheat	0.071575	474540.6	77176.5
		Barley, Beans, dry, Maize (corn), Oats, Potatoes, Sorghum, Soya beans, Wheat			
Colombia	Sorghum, Soya beans, Wheat	0.053588	544478.8	44966.88	
	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat				
Ecuador	Sorghum, Soya beans, Wheat	0.031278	199509.6	31904.22	

	Paraguay	Beans, dry, Maize (corn), Potatoes, Sorghum, Soya beans, Wheat	0.675733	3057273	49778.83
	Peru	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Rye, Sorghum, Soya beans, Wheat	0.072278	829505.4	37399.11
	Uruguay	Barley, Beans, dry, Maize (corn), Oats, Potatoes, Sorghum, Soya beans, Wheat	0.130163	544644.7	54018.88
Cluster 1	Argentina	Sugar cane	0.0174	1.87E+07	488277
	Bolivia (Plurinational State of)	Sugar cane	0.0082	1.01E+07	560599
	Colombia	Sugar cane	0.0248	2.57E+07	472762
	Ecuador	Sugar cane	0.0063	1.10E+07	790223
	Paraguay	Sugar cane	0.0048	7.43E+06	707712
	Peru	Sugar cane	0.0038	1.05E+07	1237598
	Uruguay	Sugar cane	0.0003	4.02E+05	609212
Cluster 2	Brazil	Maize (corn), Soya beans	23.2492	1.13E+08	44853.5
Cluster 3	Brazil	Sugar cane	0.4556	7.57E+08	756043

Nota: Ver Anexo C

Tabla 7. Resumen descripción de clusters obtenidos CH₄, año 2020

Nro. de Cluster	Area	Item	Crops		
			total Emissions	Production (t)	Yield (100 g/ha)
Cluster 0	Argentina	Maize (corn), Wheat	14.0703	39086375	52463
	Bolivia	Maize (corn), Wheat	0.6813	633071.5	18900
	Brazil	Wheat	2.6295	6347987	26073
	Chile	Maize (corn), Wheat	0.1979	911988	75926
	Colombia	Maize (corn), Wheat	0.49225	742652.5	32753
	Ecuador	Maize (corn), Wheat	0.46435	659765.5	30050.5
	Paraguay	Maize (corn), Wheat	1.74465	3568732	40070
	Peru	Maize (corn), Wheat	0.64965	817609	24797.5

	Uruguay	Maize (corn), Wheat	0.2858	769700	49038
Cluster 1	Brazil	Sugar cane	17.5749	7.57E+08	756043
Cluster 2	Argentina	Sugar cane	0.672	1.87E+07	488277
	Bolivia (Plurinational State of)	Sugar cane	0.316	1.01E+07	560599
	Colombia	Sugar cane	0.9556	2.57E+07	472762
	Ecuador	Sugar cane	0.2447	1.10E+07	790223
	Paraguay	Sugar cane	0.1843	7.43E+06	707712
	Peru	Sugar cane	0.1485	1.05E+07	1237598
	Uruguay	Sugar cane	0.0116	4.02E+05	609212
Cluster 3	Brazil	Maize (corn)	49.2852	1.04E+08	56955

Ver Anexo D

5. Conclusiones

En esta sección, se presentan las conclusiones derivadas del análisis realizado a lo largo de esta investigación. Estas conclusiones se basan en los resultados obtenidos.

En una primera instancia, se pudo estimar el impacto de cada uno de los cultivos seleccionados en términos de su aportación medida en emisiones de gases de efecto invernadero, observando como existen ciertos cultivos con mayor aporte con respecto a otros, como sucede en el caso del maíz y los granos de soya en el caso del N₂O, y el maíz y el trigo en el caso del CH₄, manteniéndose estas mismas tendencias de cara a sus proporciones en ambos periodos estudiados, 1990 y 2020. A su vez, es destacable el rendimiento de otros cultivos, como sucede con la caña de azúcar, encontrándose con un nivel de emisiones menor con respecto a otros cultivos y proveyendo una cantidad por hectárea sobresaliente, al ser comparada con los demás cultivos.

- Es importante reconocer la proporción de emisiones que tienen Brasil y Argentina con respecto a los demás países seleccionados, pudiendo fácilmente entre los dos representar una proporción superior al 85% del total de emisiones.
- Durante el estudio, también se ha podido observar la relación intrínseca entre variables de corte económico como el Producto Interno Bruto, con variables de corte ambiental, como los cambios en la temperatura y los niveles de emisiones de gases de efecto invernadero, estando plenamente relacionadas, como se pudo ver en el análisis de componente principales. Estos elementos, deben ser considerados en pro de evaluar las prácticas a la hora de producir, que en el caso que compete

a esta investigación, se relaciona con la búsqueda de prácticas agropecuarias menos contaminantes.

- En lo que respecta a la comparación de ambos periodos, también es destacable el hecho de cómo se mantienen relevantes y se intensifican las variables relacionadas con el cambio ambiental, como sucede en el caso de la cantidad de desastres naturales y los cambios en las precipitaciones, situación que sirve como base para generar “awareness” sobre los cambios paulatinos producidos en el planeta, producto de la acción humana.
- En la actualidad, El uso de técnicas de ciencia de datos aplicadas a este tipo de problemas representa una gran ventaja, principalmente, por la apertura que permite trabajar con lenguajes de código abierto, como Python, y disponibilidad de herramientas como Google Colab, pudiendo hacer que surjan cada vez más análisis relacionados que sirvan para crear conciencia sobre lo que viene sucediendo en nuestro contexto medioambiental.

Bibliografía

- Acciona. (s.f.). *Sostenibilidad para todos. ¿Cómo influyen los gases de efecto invernadero en el calentamiento global ?*: https://www.sostenibilidad.com/cambio-climatico/gases-efecto-invernadero-influyen-calentamiento-global/?_adin=01833301559
- Arias, F. (2012). *El proyecto de Investigación: Introducción a la investigación científica*. Epísteme.
- Cai, R., Mullen, J. D., Bergstrom, J. C., Shurley, W. D., & W. (2011). Análisis de Componentes Principales de la Respuesta del Rendimiento de los Cultivos al Cambio Climático. *Journal of Agricultural and Applied Economics*, 45(4).
https://doi.org/https://doi.org/https://www.researchgate.net/publication/254390148_Principal_Component_Analysis_of_Crop_Yield_Response_to_Climate_Change
- Calvin, k., & Fisher-Vanden, K. (2017). Quantifying the indirect impacts of climate on agriculture: a comparison between methods. *Environmental Research*, 12(11).
<https://doi.org/https://doi.org/10.1088/1748-9326/aa843>
<https://iopscience.iop.org/article/10.1088/1748-9326/aa843c/meta>
- ClimateWatch. (s.f.). *Historical Emissions*. https://www.climatewatchdata.org/data-explorer/historical-emissions?historical-emissions-data-sources=climate-watch&historical-emissions-end_year=2020&historical-emissions-gases=All%20Selected&historical-emissions-regions=LAC&historical-emissions-sectors=

- Cole, M. B., Augustin, M. A., Robertson, M. J., & Manners, J. M. (6 de Agosto de 2018). *The science of food security*. Nature: <https://www.nature.com/articles/s41538-018-0021-9>
- Epdata. (10 de enero de 2023). *El cambio climático, en datos y gráficos*.
<https://www.epdata.es/datos/cambio-climatico-datos-graficos/447>
- Faghmous, J. H., & Kumar, V. (Septiembre de 2014). *A Big Data Guide to Understanding Climate Change: The Case for Theory-Guided*. ResearchGate:
https://www.researchgate.net/publication/266573504_A_Big_Data_Guide_to_Understanding_Climate_Change_The_Case_for_Theory-Guided_Data_Science DOI:10.1089/big.2014.0026
- FAOSTAT. (s.f.). *Crops and livestock products*. <https://www.fao.org/faostat/en/#data/QCL>
- FAOSTAT. (s.f.). *Emissions from Crops*. <https://www.fao.org/faostat/en/#data/GCE>
- Ferrero, R., Lima, M., & Gonzalez-Andujar, J. (4 de Septiembre de 2017). *Crop production structure and stability under climate change in South America*. Academia:
https://www.academia.edu/45600016/Crop_production_structure_and_stability_under_climate_change_in_South_America%20doi:10.1111/aab.12402
- Foodinsight. (15 de enero de 2021). *La Agricultura y las Emisiones de Gases de Efecto Invernadero*.
<https://spanish.foodinsight.org/seguridad-alimentaria/la-agricultura-y-las-emisiones-de-gases-de-efecto-invernadero/>
- Gómez, S. (2012). *Metodología de la investigación*. Red Tercer milenio.
- Hernández Sampieri, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación (5ta edición)*. Mc Graw Hill.
- IMF Climate Change Indicators Dashboard. (s.f.). *Atmospheric CO₂ Concentrations*.
<https://climatedata.imf.org/datasets/9c3764c0efcc4c71934ab3988f219e0e/explore>
- IMF Climate Change Indicators Dashboard. (s.f.). *Climate-related Disasters Frequency*.
https://climatedata.imf.org/datasets/b13b69ee0dde43a99c811f592af4e821_0/about
- Monroy Mejía, M. D., & Nava Sanchezllanes, N. (2018). *Metodología de la investigación*. Exodo.
- Our World in Data. (s.f.). <https://ourworldindata.org/co2-and-greenhouse-gas-emissions>.
<https://ourworldindata.org/co2-and-greenhouse-gas-emissions>
- Rani, P., & Reddy, R. (2023). Climate Change and Its Impact on Food Security. *2023*, 13(3), 104-108.
<https://doi.org/DOI:10.9734/ijecc/2023/v13i31687>
- Smith, P., & Gregory, P. J. (12 de Noviembre de 2012). *Climate change and sustainable food production*. Cambridge University Press: [https://www.cambridge.org/core/journals/proceedings-of-the-](https://www.cambridge.org/core/journals/proceedings-of-the)

nutrition-society/article/climate-change-and-sustainable-food-
production/DE02043AE462DF7F91D88FD4349D38E7

Springmann, M., Mason-D’Croz, D., Robinson, S., Garnett, T., Godfray, H. C., Gollin, D., . . . Ballon, P. (7 de Mayo de 2016). *Global and regional health effects of future food production under climate change: a modelling study*. The Lancet Journal:

[https://www.thelancet.com/journals/lancet/article/PIIS0140-6736\(15\)01156-3/fulltext](https://www.thelancet.com/journals/lancet/article/PIIS0140-6736(15)01156-3/fulltext)

Tirado, M., Clarke, R., Jaykus, L., McQuatters-Gollop, A., & Frank, J. (Agosto de 2010). *Climate change and food safety: A review*. ScienceDirect:

<https://www.sciencedirect.com/science/article/abs/pii/S0963996910002231?via%3Dihub>

<https://doi.org/10.1016/j.foodres.2010.07.003>

United Nations Climate Change. (s.f.). ¿Qué es el Protocolo de Kyoto?:

https://unfccc.int/es/kyoto_protocol

World Bank. (s.f.). *Average precipitation in depth (mm per year)*.

<https://data.worldbank.org/indicator/AG.LND.PRCP.MM>

World Bank. (s.f.). *GDP -Gross domestic product -Constant 2015 US\$-*.

<https://data.worldbank.org/indicator/NY.GDP.MKTP.KD>

Anexos

Anexo A: Descripción de clusters obtenidos N20, año 1990

Nro. de Cluster	Area	Item	Crops total Emissions	Production (t)	Yield
					(100 g/ha)
Cluster 0	Brazil	Maize (corn)	4.7866	21347770	18735
	Argentina	Soya beans	2.9182	10700000	21566
	Brazil	Soya beans	5.9412	19897804	17322

	Argentina	Wheat	2.8134	10055700	18947
Cluster 1	Argentina	Barley	0.0824	326600	21934
	Bolivia	Barley	0.0233	65064	6820
	Brazil	Barley	0.0432	157353	14976
	Chile	Barley	0.0215	91585	34797
	Colombia	Barley	0.0262	100400	18490
	Ecuador	Barley	0.0142	42249	7955
	Peru	Barley	0.0225	71638	9539
	Uruguay	Barley	0.0347	133500	18803
	Argentina	Beans, dry	0.0502	207845	10021
	Bolivia	Beans, dry	0.0026	12360	12431
	Brazil	Beans, dry	0.8909	2234467	4774
	Chile	Beans, dry	0.0184	87088	12702
	Colombia	Beans, dry	0.0366	132150	8029
	Ecuador	Beans, dry	0.0096	26380	5411
	Paraguay	Beans, dry	0.0112	47083	10235
	Peru	Beans, dry	0.0137	50337	8270
	Uruguay	Beans, dry	0.0011	3650	7052
	Argentina	Maize (corn)	1.0106	5400000	34608
	Bolivia	Maize (corn)	0.0916	390952	16658
	Chile	Maize (corn)	0.1333	823150	81395
	Colombia	Maize (corn)	0.3007	1213300	14498
	Ecuador	Maize (corn)	0.1332	465399	10602
	Paraguay	Maize (corn)	0.0892	420019	21991
	Peru	Maize (corn)	0.1396	631815	19532
	Uruguay	Maize (corn)	0.0253	112313	18510
	Argentina	Millet	0.0148	65300	13219
	Argentina	Oats	0.1756	695000	15403
	Bolivia	Oats	0.0012	3244	7243
	Brazil	Oats	0.056	177760	9201
	Chile	Oats	0.0441	205465	26241
	Colombia	Oats	0.0004	1600	20000
	Ecuador	Oats	0.0003	1036	9072
Peru	Oats	0.0007	636	1514	
Uruguay	Oats	0.0154	51033	10012	

Argentina	Potatoes	0.0633	1598170	202747
Bolivia	Potatoes	0.061	619759	51779
Brazil	Potatoes	0.1081	2233721	141084
Chile	Potatoes	0.0386	828752	150300
Colombia	Potatoes	0.1138	2464400	152736
Ecuador	Potatoes	0.0282	368605	71727
Paraguay	Potatoes	0.0001	1340	67000
Peru	Potatoes	0.0823	1153979	78805
Uruguay	Potatoes	0.0109	173850	95000
Argentina	Rye	0.0175	55100	8103
Bolivia	Rye	0.0001	183	5810
Brazil	Rye	0.0013	4535	10319
Chile	Rye	0.0013	6174	26996
Ecuador	Rye	0	85	2891
Peru	Rye	0.0002	503	4195
Argentina	Sorghum	0.4221	2050000	28116
Bolivia	Sorghum	0.0097	50720	35895
Brazil	Sorghum	0.0592	236250	17150
Colombia	Sorghum	0.1594	777400	28476
Ecuador	Sorghum	0.0006	2963	28273
Paraguay	Sorghum	0.0043	14208	11646
Peru	Sorghum	0.0027	13018	27036
Uruguay	Sorghum	0.0132	59381	22680
Bolivia	Soya beans	0.0715	232743	16234
Chile	Soya beans	0	0	0
Colombia	Soya beans	0.0652	232140	19986
Ecuador	Soya beans	0.047	166694	19873
Paraguay	Soya beans	0.5048	1794618	19942
Peru	Soya beans	0.0007	2547	20998
Uruguay	Soya beans	0.0127	37000	12982
Bolivia	Wheat	0.0209	54480	6480
Brazil	Wheat	0.9729	3093791	11540
Chile	Wheat	0.4476	1718214	29481
Colombia	Wheat	0.0295	104800	18483
Ecuador	Wheat	0.0106	29907	7967

	Paraguay	Wheat	0.0746	259337	16571
	Peru	Wheat	0.0283	88487	10847
	Uruguay	Wheat	0.1173	417400	18510
Cluster 2	Argentina	Sugar cane	0.0116	15700000	614123
	Bolivia	Sugar cane	0.0038	3880186	463754
	Colombia	Sugar cane	0.0145	27790736	873006
	Ecuador	Sugar cane	0.0039	5720897	671703
	Paraguay	Sugar cane	0.0027	2449329	408222
	Peru	Sugar cane	0.0028	6700000	1089431
	Uruguay	Sugar cane	0.0005	682800	665757
Cluster 3	Brazil	Sugar cane	0.1944	2.63E+08	614788

Anexo B: Descripción de clusters obtenidos CH₄, año 1990

Nro. de Cluster	Area	Item	Crops total Emissions	Production (t)	Yield (100 g/ha)
Cluster 0	Argentina	Sugar cane	0.4487	15700000	614123
	Bolivia	Sugar cane	0.1468	3880186	463754
	Colombia	Sugar cane	0.5587	27790736	873006
	Ecuador	Sugar cane	0.1495	5720897	671703
	Paraguay	Sugar cane	0.1053	2449329	408222
	Peru	Sugar cane	0.1079	6700000	1089431
	Uruguay	Sugar cane	0.018	682800	665757
Cluster 1	Brazil	Sugar cane	7.4984	2.63E+08	614788
Cluster 2	Argentina	Maize (corn)	4.2129	5400000	34608
	Bolivia	Maize (corn)	0.6337	390952	16658
	Chile	Maize (corn)	0.2731	823150	81395
	Colombia	Maize (corn)	2.2596	1213300	14498
	Ecuador	Maize (corn)	1.1852	465399	10602
	Paraguay	Maize (corn)	0.5157	420019	21991
	Peru	Maize (corn)	0.8734	631815	19532
	Uruguay	Maize (corn)	0.1638	112313	18510
	Argentina	Wheat	5.7319	10055700	18947
	Bolivia	Wheat	0.0908	54480	6480
	Brazil	Wheat	2.8955	3093791	11540
	Chile	Wheat	0.6294	1718214	29481

	Colombia	Wheat	0.0612	104800	18483
	Ecuador	Wheat	0.0405	29907	7967
	Paraguay	Wheat	0.169	259337	16571
	Peru	Wheat	0.0881	88487	10847
	Uruguay	Wheat	0.2435	417400	18510
Cluster 3	Brazil	Maize (corn)	30.7646	21347770	18735

Anexo C: Descripción de clusters obtenidos N20, año 2020

Nro. de Cluster	Area	Item	Crops total Emissions	Production (t)	Yield
					(100 g/ha)
Cluster 0	Argentina	Barley	1.0306	4.48E+06	41082
	Bolivia	Barley	0.0154	4.76E+04	8798
	Brazil	Barley	0.0901	3.87E+05	37089
	Chile	Barley	0.0426	1.93E+05	64790
	Colombia	Barley	0.0016	6.15E+03	21769
	Ecuador	Barley	0.0041	1.41E+04	12647
	Peru	Barley	0.0548	2.03E+05	16176
	Uruguay	Barley	0.1413	6.07E+05	36792
	Argentina	Beans, dry	0.1324	6.34E+05	12982
	Bolivia	Beans, dry	0.0218	1.03E+05	12748
	Brazil	Beans, dry	0.6842	3.04E+06	11297
	Chile	Beans, dry	0.0019	9.18E+03	12765
	Colombia	Beans, dry	0.0243	1.14E+05	12481
	Ecuador	Beans, dry	0.0037	1.19E+04	6610
	Paraguay	Beans, dry	0.0173	6.98E+04	9584
	Peru	Beans, dry	0.0185	8.72E+04	12678
	Uruguay	Beans, dry	0.001	3.07E+03	6357
	Argentina	Maize (corn)	9.544	5.84E+07	75539
	Bolivia	Maize (corn)	0.201	9.55E+05	22580
	Chile	Maize (corn)	0.0948	5.93E+05	91814
Colombia	Maize (corn)	0.2671	1.48E+06	40674	
Ecuador	Maize (corn)	0.2388	1.30E+06	38233	
Paraguay	Maize (corn)	1.0032	5.83E+06	53042	

Peru	Maize (corn)	0.2736	1.45E+06	33261
Uruguay	Maize (corn)	0.1271	7.63E+05	65390
Argentina	Millet	0.0012	5.44E+03	15488
Argentina	Oats	0.1421	6.00E+05	18618
Bolivia	Oats	0.0059	2.32E+04	15455
Brazil	Oats	0.2118	8.98E+05	18879
Chile	Oats	0.0904	4.77E+05	49219
Colombia	Oats	0	0.00E+00	0
Ecuador	Oats	0.0003	8.79E+02	7452
Peru	Oats	0.0059	2.26E+04	14140
Uruguay	Oats	0.0102	4.55E+04	21933
Argentina	Potatoes	0.0887	2.88E+06	360771
Bolivia	Potatoes	0.1002	1.32E+06	72235
Brazil	Potatoes	0.1211	3.77E+06	321337
Chile	Potatoes	0.0431	1.29E+06	291801
Colombia	Potatoes	0.1023	2.63E+06	209308
Ecuador	Potatoes	0.0181	4.08E+05	164098
Paraguay	Potatoes	0.0002	3.98E+03	143791
Peru	Potatoes	0.2434	5.52E+06	165551
Uruguay	Potatoes	0.0029	7.37E+04	202378
Argentina	Rye	0.0507	2.21E+05	20381
Bolivia	Rye	0.0001	2.84E+02	7867
Brazil	Rye	0.0022	9.26E+03	17314
Chile	Rye	0.0009	4.46E+03	46985
Ecuador	Rye	0	8.09E+01	6308
Peru	Rye	0	3.20E+01	10667
Argentina	Sorghum	0.3267	1.83E+06	46303
Bolivia	Sorghum	0.2268	1.02E+06	22674
Brazil	Sorghum	0.5495	2.77E+06	31501
Colombia	Sorghum	0.0012	5.81E+03	24932
Ecuador	Sorghum	0.0035	1.36E+04	16083
Paraguay	Sorghum	0.0208	1.08E+05	34796
Peru	Sorghum	0	1.37E+02	44079
Uruguay	Sorghum	0.0178	9.88E+04	44909
Argentina	Soya beans	11.9639	4.88E+07	29182

	Bolivia	Soya beans	0.7821	2.83E+06	20835
	Chile	Soya beans	0	0.00E+00	0
	Colombia	Soya beans	0.0305	1.19E+05	25739
	Ecuador	Soya beans	0.009	2.72E+04	13839
	Paraguay	Soya beans	2.6695	1.10E+07	30362
	Peru	Soya beans	0.0004	1.53E+03	23706
	Uruguay	Soya beans	0.5414	1.99E+06	21706
	Argentina	Wheat	5.1538	1.98E+07	29387
	Bolivia	Wheat	0.0912	3.11E+05	15220
	Brazil	Wheat	1.6824	6.35E+06	26073
	Chile	Wheat	0.2989	1.23E+06	60038
	Colombia	Wheat	0.0017	6.30E+03	24832
	Ecuador	Wheat	0.004	1.46E+04	21868
	Paraguay	Wheat	0.3434	1.30E+06	27098
	Peru	Wheat	0.0539	1.87E+05	16334
	Uruguay	Wheat	0.1996	7.76E+05	32686
Cluster 1	Argentina	Sugar cane	0.0174	1.87E+07	488277
	Bolivia	Sugar cane	0.0082	1.01E+07	560599
	Colombia	Sugar cane	0.0248	2.57E+07	472762
	Ecuador	Sugar cane	0.0063	1.10E+07	790223
	Paraguay	Sugar cane	0.0048	7.43E+06	707712
	Peru	Sugar cane	0.0038	1.05E+07	1237598
	Uruguay	Sugar cane	0.0003	4.02E+05	609212
Cluster 2	Brazil	Maize (corn)	17.6717	1.04E+08	56955
	Brazil	Soya beans	28.8267	1.22E+08	32752
Cluster 3	Brazil	Sugar cane	0.4556	7.57E+08	756043

Anexo D: Descripción de clusters obtenidos CH4, año 2020

Nro. de Cluster	Area	Item	Crops		
			total Emissions	Production (t)	Yield (100 g/ha)
Cluster 0	Argentina	Maize (corn)	20.8724	5.84E+07	75539
		Maize (corn)	1.1417	9.55E+05	22580
	Bolivia (Plurinational State of)	(corn)			

		Maize			
	Chile	(corn)	0.1744	5.93E+05	91814
		Maize			
	Colombia	(corn)	0.9818	1.48E+06	40674
		Maize			
	Ecuador	(corn)	0.9215	1.30E+06	38233
		Maize			
	Paraguay	(corn)	2.97	5.83E+06	53042
		Maize			
	Peru	(corn)	1.1758	1.45E+06	33261
		Maize			
	Uruguay	(corn)	0.3151	7.63E+05	65390
	Argentina	Wheat	7.2682	1.98E+07	29387
	Bolivia (Plurinational State of)	Wheat	0.2209	3.11E+05	15220
	Brazil	Wheat	2.6295	6.35E+06	26073
	Chile	Wheat	0.2214	1.23E+06	60038
	Colombia	Wheat	0.0027	6.30E+03	24832
	Ecuador	Wheat	0.0072	1.46E+04	21868
	Paraguay	Wheat	0.5193	1.30E+06	27098
	Peru	Wheat	0.1235	1.87E+05	16334
	Uruguay	Wheat	0.2565	7.76E+05	32686
Cluster 1	Brazil	Sugar cane	17.5749	7.57E+08	756043
Cluster 2	Argentina	Sugar cane	0.672	1.87E+07	488277
	Bolivia (Plurinational State of)	Sugar cane	0.316	1.01E+07	560599
	Colombia	Sugar cane	0.9556	2.57E+07	472762
	Ecuador	Sugar cane	0.2447	1.10E+07	790223
	Paraguay	Sugar cane	0.1843	7.43E+06	707712
	Peru	Sugar cane	0.1485	1.05E+07	1237598
	Uruguay	Sugar cane	0.0116	4.02E+05	609212
		Maize			
Cluster 3	Brazil	(corn)	49.2852	1.04E+08	56955