

# Pontificia Universidad Católica del Perú

Facultad de Ciencias e Ingeniería



**PROPUESTA DE MEJORA DE LA CADENA DE SUMINISTROS DE LA PALTA  
MEDIANTE EL USO DE HERRAMIENTAS DE ANÁLISIS DE SERIES DE TIEMPO,  
ANALYTICS Y OPTIMIZACIÓN MATEMÁTICA**

**Tesis para obtener el título profesional de Ingeniero Industrial**

**AUTOR:**

César Eduardo Goyzueta Meneses

**ASESOR:**

Profesor: Ing. Jonatán Edward Rojas Polo

Lima, septiembre de 2021

## RESUMEN DE TESIS

La tesis que estaré presentando es sobre una propuesta de mejora de la cadena de suministros de la palta mediante el uso de herramientas de análisis de series de tiempo, analytics y optimización matemática. Se divide en marco teórico, donde se muestra un panorama claro sobre la investigación operativa, cadena de suministro, analítica y series de tiempo; para comprender lo que se abarcará. El segundo capítulo sería sobre casos de estudio similares al enfoque del estudio. El siguiente capítulo sería un análisis del Perú enfocado en la exportación de la palta, su capacidad hídrica, superficie agrícola disponible, informalidad y pobreza. En el cuarto capítulo se propondrá una propuesta de mejora utilizando información climática, potenciales mercados a exportar, información socioeconómica, rendimientos de los terrenos y limitantes hídricas como de terreno; usando las herramientas de series de tiempo, analytics y un modelo matemático. Para el quinto capítulo se realizará el análisis financiero para ver si es rentable para los agricultores implementar la cosecha de la palta. En el siguiente capítulo se analizarán los datos otorgados por el modelo, el análisis descriptivo y el análisis financiero. Para finalizar, el último capítulo abarcará las conclusiones a partir de lo evaluado durante el documento.

## DEDICATORIA

Agradezco a Dios por su cuidado y guía en todo este tiempo universitario, amigos y amigas en la universidad por tener esta bonita etapa. A mis padres por todo el apoyo económico y emocional que me brindaron en toda esta trayectoria que fue larga pero muy bonita y formativa y a Sharont Fernandez por el apoyo en la realización de la tesis con los ánimos. Anhelo que Dios me guíe en lo que sigue a partir de esta etapa y que se haga Su voluntad en mi vida, espero poder darle la gloria con esta carrera que ando culminando.



## TEMA DE TESIS

**TEMA** : PROPUESTA DE MEJORA DE LA CADENA DE SUMINISTROS DE LA PALTA MEDIANTE EL USO DE HERRAMIENTAS DE ANÁLISIS DE SERIES DE TIEMPO, ANALYTICS Y OPTIMIZACIÓN MATEMÁTICA

**ÁREA** : Ingeniería Industrial

**ASESOR** : Ing. Jonatán E. Rojas Polo

**ALUMNO(S)** : César Eduardo Goyzueta Meneses

**FECHA** : ----

---

### JUSTIFICACIÓN:

El Perú además de ser conocido internacionalmente por su cultura, variedad y comida; también lo es, en el ámbito de negocios, como un país minero e hidrocarburos con un aproximado de 9% del PBI y con presencia del 60% en exportaciones peruanas en los últimos 10 años<sup>1</sup> según Pablo de la Flor, director de la Sociedad Nacional de Minería, Petróleo y Energía (SNMPE). Sin embargo, no solamente la minería tiene gran presencia en el PBI, sino también su agricultura. Según Oscar Chávez, jefe del Instituto de Economía y Desarrollo Empresarial (IEDEP) de la Cámara de Comercio de Lima 5.4%del PBI y, además, el 24.2% de la Población Económicamente Activa (PEA) total<sup>2</sup>. Además, tiene grandes beneficios en generación de empleos. Según Pedro Grados Smith, director de la Carrera de Economía de la Universidad de Lima, comentó en RPP el 11 de agosto del 2020 que a pesar de ser aproximadamente 6% del PBI nacional, el sector agropecuario genera 451 mil empleos formales en la costa peruana<sup>3</sup>; asimismo, el Banco Mundial afirmó en el 2018 que impulsar la agricultura es uno de los pilares para luchar contra la pobreza en el Perú y que tiene una gran participación en la generación de empleos formales e informales<sup>4</sup>.

---

<sup>1</sup> El Peruano.(2020).Minería: Ejecución de cartera de 48 proyectos crearía más de 600,000 empleos.Lima

<sup>2</sup> Agencia agraria de noticias.Sector agrario emplea a más de 4 millones de peruanos.(2019).

<sup>3</sup> Universidad de Lima(2020). Importancia del crecimiento del sector agricultura para el empleo. Lima

<sup>4</sup> El Peruano.(2018).Agro genera 1 de cada 4 empleos formales en el Perú.Lima

Por otro lado, si hay mercado para los productos agrícolas peruanos en el exterior. En la publicación de la revista El Peruano del 2018, se resaltó que “los productos agrícolas peruanos están incrementando su presencia en los mercados suizos.” En el 2019 el BBVA realizó un informe elaborado por *BBVA Research* que muestra que el porcentaje de superficie agrícola utilizada para la exportación subió de un 10% (2017) al 18% (2018). Además, que existen oportunidades de mercado con China en gran manera, y también con India y Turquía, en los cuales su importación de alimentos va creciendo por encima del promedio. Por otro lado, comenta en su publicación: “considera necesario impulsar la reducción de costos logísticos, que vienen mermando la competitividad de las exportaciones peruanas, e incluso se consolidan como una importante fuente de costo en los principales productos agrícolas. De acuerdo con el Índice de Desempeño Logístico, se ha detectado un deterioro en el desempeño de la calidad de los servicios logísticos y en la calidad de la infraestructura.”

Viendo toda esta información en el tiempo hasta el día de hoy, se ve que hay una necesidad de mejora latente en la cadena de suministro agrícola. Esta es la motivación inicial de este trabajo, dar una mejora en la cadena de suministro y mostrar el potencial de Perú para que se desarrolle la exportación de la palta. Por medio de las exportaciones se crea un camino a la generación de trabajo y reducción de nivel de pobreza en el Perú. Más allá de un beneficio económico, también hay un potencial beneficio social.

#### **OBJETIVO GENERAL:**

Proponer un plan de mejora de la cadena de suministros para maximizar el beneficio socio-económico y el mejor uso de los recursos.

#### **OBJETIVOS ESPECÍFICOS:**

- Definir los fundamentos teóricos de la programación lineal aplicables a la cadena de suministros y de las herramientas descriptivas de analítica.
- Describir la situación actual del Perú en el sector agrónomo enfocado en su producción por distrito, nivel de exportación como país y en su cadena de suministro.
- Proponer mediante herramientas una mejora para elegir los lugares con más beneficios socioeconómico y proponer un nivel de producción por distrito idóneo según factores exógenos al país.
- Análisis de la propuesta, que tenga como base indicadores acorde al tema y contrastarla con la situación actual para probar la viabilidad de la propuesta.

#### **PUNTOS A TRATAR:**

**a. Marco teórico**

Explicar el uso de programación lineal para el desarrollo del modelo matemático tomando en cuenta la cadena de suministro de la palta. Se presentarán herramientas descriptivas de analítica para comprender de mejor manera los datos y de series de tiempo para pronosticar la demanda del mercado. Además, se explicará la teoría de lo que implica una cadena de suministros.

**b. Estudio de casos**

Mostrar trabajos llamados *papers* para tener un panorama amplio acerca del contexto del campo de la agricultura y las mejoras en ellas, además de los métodos aplicados para lograr optimizaciones.

**c. Descripción de entidad**

Describir las características de Perú como país y delimitar el tema de estudio de la tesis que es la exportación de la palta como actividad económica relevante, sus recursos y atributos cualitativos de los distritos.

**d. Propuesta de mejora**

Emplear las herramientas del marco teórico para realizar una propuesta de mejora óptima.

**e. Análisis de resultados**

Analizar los resultados de la propuesta de mejora.

**f. Conclusiones y recomendaciones.**

---

Asesor:



# ÍNDICE

OBJETIVO GENERAL:	iv
OBJETIVOS ESPECÍFICOS:	iv
PUNTOS A TRATAR:	iv
ÍNDICE	1
ÍNDICE DE FIGURAS	5
ÍNDICE DE TABLAS	6
ÍNDICE DE GRÁFICOS	7
CAPÍTULO 1: MARCO TEÓRICO	8
1.1. Investigación operativa	8
1.1.1. Modelo base de optimización	8
1.1.2. Estructura para la construcción de modelos matemáticos	8
1.1.3. Pasos para la construcción de modelos matemáticos	10
1.1.4. Formas de solucionar el problema	12
1.1.5. Programación entera	13
1.1.6. Programación entera binaria	13
1.1.7. Programación entera positiva	15
1.1.8. Programación entera mixta	15
1.2. Cadena de Suministro o Supply Chain	16
1.2.1. Definición	16
1.2.1. Los tres pilares de la sustentabilidad	18
1.3. Analítica	18
1.3.1. Definición	18
1.3.2. Etapas de la analítica	20
1.3.3. Lenguajes de programación	21
1.3.4. Principales componentes de análisis – PCA	23
1.3.5. Dendograma	25
1.3.6. Árbol de decisión	27
1.3.7. Clustering	31
1.4. Series de datos temporales	32
1.4.1. Introducción	32
1.4.2. Ruido Blanco	33
1.4.3. Supuestos y tratamientos de datos	33
1.4.4. Caminata Aleatoria	34



1.4.4. ACF ( <i>Auto-correlation Function</i> ).....	35
1.4.5. PACF ( <i>Partial Auto-correlation Function</i> ).....	35
1.4.6. Autorregresivo (AR) .....	36
1.4.7. Media Móvil (MA).....	37
1.4.9. ARIMA .....	39
<b>CAPÍTULO 2: CASOS DE ESTUDIO</b> .....	41
2.1. <i>Agri-food 4.0</i> : Una encuesta de las cadenas de suministros y futuras tecnologías en la agricultura .....	41
2.1.1. Nuevas herramientas utilizadas en <i>Agri-Food 4.0</i> .....	41
2.1.2. Cómo las nuevas tecnologías transforman la cadena de suministro de la agricultura .....	42
2.2. La integración basada en el aprendizaje automático de los factores de sequía detectados de forma remota puede mejorar la estimación de la sequía agrícola en el sureste de Australia .....	46
2.2.1. Alcance del estudio .....	47
2.2.2. Datos .....	47
2.2.3. Metodología .....	49
2.2.4. Resultados .....	50
<b>CAPÍTULO 3: ANÁLISIS DEL PERÚ</b> .....	52
3.1. Actividades económicas .....	52
3.2. La palta.....	53
3.3. Exportaciones e importaciones de Perú con la palta.....	54
3.3.1. Importación de la palta .....	54
3.3.2. Exportación de la palta.....	56
3.4. La palta en el Perú.....	58
3.5. Capacidad hídrica del Perú.....	61
3.5.1. Huella hídrica .....	61
3.5.2. Tipo de extracciones .....	61
3.5.3. Tipos de agua.....	61
3.5.4. Disponibilidad de agua.....	61
3.6 Superficie agrícola disponible .....	68
3.7 Informalidad y pobreza .....	69
<b>CAPÍTULO 4: PROPUESTA DE MEJORA</b> .....	72
4.1 Características climáticas de los distritos .....	72
4.2 Potenciales mercados para exportar .....	76
4.2.1 China.....	76
4.2.2 Estados Unidos .....	79

4.2.3 Países Bajos .....	80
4.3 Mercado disponible en Estados Unidos y Países Bajos .....	82
4.3.1 Mercado disponible de Estados Unidos .....	82
4.3.2 Mercado disponible de Países Bajos .....	84
4.3.3 Mercado disponible total.....	85
4.4 Modelo matemático propuesto .....	86
4.4.1 Supuestos .....	86
4.4.2 Parámetros del modelo.....	87
4.4.3 Variables de decisión.....	87
4.4.4 Índices.....	87
4.4.5 Modelo matemático .....	88
4.4 Modelo matemático propuesto en AMPL.....	89
<b>CAPITULO 5: ANÁLISIS FINANCIERO .....</b>	<b>92</b>
5.1 Costos para implementación de una hectárea.....	92
5.2 Costo de oportunidad .....	92
5.3 Costo promedio ponderado de capital .....	95
5.4 Flujo de caja.....	96
5.5 Indicadores financieros .....	98
<b>CAPÍTULO 6: ANÁLISIS DE RESULTADOS.....</b>	<b>100</b>
6.1 Análisis descriptivo .....	100
6.2 Resultados del modelo .....	100
6.3 Análisis del flujo de caja.....	101
<b>CAPÍTULO 7: CONCLUSIONES .....</b>	<b>102</b>
7.1 Conclusiones.....	102
7.2 Recomendaciones.....	103
<b>BIBLIOGRAFÍA.....</b>	<b>105</b>
<b>ANEXOS.....</b>	<b>108</b>
Anexo 1: Manual AMPL para comprensión de la tesis .....	108
Anexo 2: Tabla input para el análisis PCA .....	114
Anexo 3: Datos de entrada para el modelo AMPL.....	137
Anexo 4 : Métricas por distrito .....	141
Anexo 5: Hectáreas libres por distrito.....	142
Anexo 6: Tabla de capacidad hídrica por distrito .....	143
Anexo 7: Resultado de AMPL – activador binario mensual de distrito .....	144
Anexo 8: Resultado de AMPL – activador binario anual de distrito.....	145
Anexo 9: Resultado de AMPL toneladas por distrito-meses.....	146

<b>Anexo 10: Flujo de kilos cosechados escenario probable .....</b>	<b>147</b>
<b>Anexo 11: Flujo económico probable.....</b>	<b>148</b>
<b>Anexo 12: Flujo económico pesimista .....</b>	<b>149</b>
<b>Anexo 13: Flujo económico optimista.....</b>	<b>150</b>
<b>Anexo 14: Flujo de crédito bancario probable .....</b>	<b>151</b>
<b>Anexo 15: Flujo de crédito bancario pesimista .....</b>	<b>151</b>
<b>Anexo 16: Flujo de crédito bancario optimista .....</b>	<b>152</b>
<b>Anexo 17: Flujo financiero probable.....</b>	<b>153</b>
<b>Anexo 18: Flujo financiero pesimista .....</b>	<b>153</b>
<b>Anexo 19: Flujo financiero optimista.....</b>	<b>153</b>
<b>Anexo 20 : Script de PCA.....</b>	<b>155</b>
<b>Anexo 21: Script de series de tiempo.....</b>	<b>158</b>



# ÍNDICE DE FIGURAS

Figura 1 : Panorama de la cadena de suministro .....	16
Figura 2: Ejemplo de panorama parcial de una empresa de cosméticos .....	17
Figura 3: Pirámide del conocimiento .....	19
Figura 4: Etapas de analítica.....	19
Figura 5: Logo de Python.....	22
Figura 6: Logo de R.....	23
Figura 7: Métodos de principales componentes.....	24
Figura 8: Ejemplo gráfico de cambio de ejes.....	25
Figura 9: Ejemplo gráfico de redundancia de los datos .....	25
Figura 10: Agrupamiento por distancia para el dendograma .....	26
Figura 11: Dendograma .....	26
Figura 12: Límites de decisión en árbol de decisión.....	28
Figura 13: Recomendación de porcentaje en conjunto de entrenamiento y de prueba ...	28
Figura 14: Explicación de elementos de árbol de decisión.....	29
Figura 15: Efectos de la poda .....	29
Figura 16: Matriz de confusión.....	30
Figura 17: Mapa de áreas de cultivo de secano .....	47
Figura 18 : Correlación de las variables .....	50
Figura 19 : Evaluación precisión y error de los modelos .....	51
Figura 20: Evolución en USD millones en la exportación agrícola peruana.....	53
Figura 21: Mapa del Perú con nivel de intensidad según lo cosechado por Departamento .....	59
Figura 22: Distribución por modo de transporte - 2014.....	60
Figura 23: Distribución de recursos hídrico a nivel nacional .....	62
Figura 24: Uso de agua predominante por Administración Local de Agua y porcentaje de agua utilizado para dicho uso.....	64
Figura 25: Mapa de porcentaje de pobreza 2018 .....	71
Figura 26: Datos de la palta.....	72
Figura 27: Posición relativa de los países en contraste con los otros .....	78

## ÍNDICE DE TABLAS

Tabla 1: Impactos de Big Data Analytics.....	43
Tabla 2: Retos de Big Data Analytics.....	44
Tabla 3: Impactos de la Inteligencia artificial .....	45
Tabla 4: Retos de la Inteligencia Artificial.....	46
Tabla 5: Índices para la predicción de sequías agrícolas en el New South Wales .....	48
Tabla 6: Datos de BOM.....	48
Tabla 7: Descripción de las áreas de nivel 2 (SA2) regiones de New South Wales .....	49
Tabla 8: Actividades de la palta en el comercio exterior.....	55
Tabla 9: Evolución de las importaciones de palta por país .....	56
Tabla 10 : Top 10 de países exportadores de palta en toneladas .....	56
Tabla 11: Top 10 de países exportadores de palta en toneladas .....	57
Tabla 12 : Rendimientos por provincia .....	60
Tabla 13: Relación de disponibilidad vs población .....	63
Tabla 14: Consumo no consuntivo 2009 y 2016.....	65
Tabla 15: Proyección de no consuntivo.....	65
Tabla 16: Consumo por vertiente a partir de hidroeléctricas.....	65
Tabla 17: Uso consuntivo por vertiente .....	66
Tabla 18: Uso consuntivo por rubro necesario para el 2025.....	66
Tabla 19: Recurso hídrico disponible para el 2025.....	66
Tabla 20: Hectáreas disponibles por distrito abastecidos por la vertiente del Atlántico ....	67
Tabla 21: Razones por la que no se trabaja la superficie agrícola .....	68
Tabla 22: Superficie agrícola disponible por distrito .....	69
Tabla 23: Porcentaje de informalidad por departamento .....	70
Tabla 24: Distritos que se analizaron.....	73
Tabla 25: Porcentaje por año de los países según las exportaciones mundiales .....	76
Tabla 26: Países a donde exporta Perú, los 15 más representativos .....	76
Tabla 27: Importación del 2020 de Perú a EE.UU. y su proyección al 2021.....	83
Tabla 28: Importación del 2020 de Perú a Países Bajos. y su proyección al 2021.....	85
Tabla 29: Total del mercado disponible.....	85
Tabla 30: Valor para exportar por mes modificados.....	86
Tabla 31: Valor de exportación por mes para el modelo .....	86
Tabla 32: Tabla de precios de la palta Hass por kilo.....	97
Tabla 33: Panorama de flujo económico .....	97
Tabla 34: VAN(WACC).....	98
Tabla 35: VAN(COK) .....	98
Tabla 36: TIR .....	99
Tabla 37: Cantidad de toneladas por distrito-mes .....	101

# ÍNDICE DE GRÁFICOS

Gráfico 1: Ruido blanco.....	33
Gráfico 2: Caminata aleatoria con $c=0$ .....	34
Gráfico 3: Caminata aleatoria con $c=1$ .....	35
Gráfico 4: ACF y PACF del modelo AR.....	37
Gráfico 5: ACF de un modelo MA.....	38
Gráfico 6: PACF de un modelo MA.....	38
Gráfico 7: ACF y PACF del modelo ARMA.....	39
Gráfico 8: Tratamiento de Datos.....	40
Gráfico 9: Importaciones por año en toneladas de Perú.....	55
Gráfico 10: Toneladas de palta exportadas por el Perú del 2000 al 2018.....	57
Gráfico 11: Evolución de importaciones de Países Bajos, Japón, China, España, Reino Unido y Estados Unidos.....	58
Gráfico 12: Relación de disponibilidad de agua por población ( $m^3/hab.$ ) por vertiente hidrográfica (1985; 1992 y 2013).....	63
Gráfico 13: Distritos en el gráfico de principales componentes.....	74
Gráfico 14: Elbow method para la selección de cantidad de cluster.....	75
Gráfico 15: Dendograma de los distritos.....	75
Gráfico 16: Importaciones de China por año-mes y países.....	77
Gráfico 17: Importaciones mensuales de China.....	78
Gráfico 18: Importaciones mensuales de Estados Unidos.....	79
Gráfico 19: Importaciones mensuales de Estados Unidos.....	80
Gráfico 20: Importaciones de Países Bajos.....	81
Gráfico 21: Importaciones mensuales de Países Bajos.....	82
Gráfico 22: Importaciones históricas y proyectadas de Estados Unidos.....	83
Gráfico 23: Importaciones históricas y proyectadas de Países Bajos.....	84
Gráfico 24: Indicador de apalancamiento financiero para empresas con ventas netas mayores a 300 UIT.....	93
Gráfico 25: Rendimiento del bono EE. UU con plazo de 10 años (últimos 3 años).....	94
Gráfico 26: Riesgo país de Perú desde el periodo de agosto de 2006 hasta febrero 2021.....	95

# **CAPÍTULO 1: MARCO TEÓRICO**

## **1.1. Investigación operativa**

La investigación operativa nace la idea desde el comienzo de la Revolución Industrial donde se buscaba superar el subdesarrollo mediante el mejor uso de sus recursos para realizar las operaciones que demandaba la fábrica en ese periodo. A partir de ahí se fue buscando la mejora no solo en fábricas sino en otros ámbitos laborales donde se buscaba optimizar el uso de sus recursos limitados. Su enfoque es en la necesidad administrativa de poder realizar decisiones para el uso de sus recursos y tiempo de la mejor manera, debido a que de manera empírica no siempre llega a la mejor resolución posible; además el costo y tiempo que se evita al realizar intentos en llegar al óptimo de manera empírica es notablemente menor en contraste con los métodos que esta ciencia propone. (Hillier, 2001)

### **1.1.1. Modelo base de optimización**

#### **Introducción**

En esta ciencia se tienen diversas opciones de modelos matemáticos de optimización donde cada uno se ajusta a determinadas condiciones de problema. Eso conlleva que fueron planteados para resolver un tipo de problema con restricciones y condiciones ya establecidas, significa que si se desea aplicar los modelos ya existentes se deben comprenderlos y ver si la situación en donde se desea aplicar se ajusta al modelo. Sin embargo, que no se ajuste no significa que no se pueda resolver por esta metodología, sino que se tendrá que plantear un nuevo modelo para la problemática o modificar modelos ya existentes.

Los modelos matemáticos que se utilizan se basan en un modelo base para la invención de ellos. El modelo base tiene los siguientes elementos: (Winston, 2005)

- Función objetivo
- Variables de decisión
- Parámetros
- Restricciones
- Rango de existencia de las variables de decisión

### **1.1.2. Estructura para la construcción de modelos matemáticos**

Se explicará la teoría del modelamiento matemático basándose en Hillier (2010), Winston (2005) y Taha (2004).

## **Función objetivo**

Para poder modelar la función objetivo se tiene que comprender cuál es la necesidad de la problemática, qué es lo que se desea optimizar; unos ejemplos podrían ser maximizar las utilidades, utilización de recursos, entre otros; en el caso de minimización, se puede dar el caso que sea reducción de costos, uso de materiales, etcétera.

Un ejemplo de una función objetivo básico vendría a ser el que se muestra a continuación. donde las variables de decisión con  $X_i$ , son los ingresos que recibe una empresa por “i” productos;  $Y_i$ , son los costos de los “i” productos y  $Z$  es el costo fijo que la empresa debe asumir, se encuentra afuera de la sumatoria debido a que es un valor fijo que no depende de las operaciones de la empresa en el tema de producción.

$$\text{Maximizar } \sum_{i=1}^{100} (X_i - Y_i) - Z$$

Lo planteado previamente busca llegar al mejor uso de sus recursos para producir los “i” productos. La respuesta a la que se llegará depende también de las restricciones, las cuales se explicarán más adelante.

## **Variables de decisión**

Son todas las variables que se ven involucradas y puedan afectar a la función objetivo, no pueden llegar a ser negativas. Se debe tomar en cuenta la relevancia de las variables a elegir si se está creando un nuevo modelo matemático de optimización; y en el caso de uno existente se debe analizar cómo se relaciona con la función objetivo para que haya una mayor comprensión de ellas. Se usan para plantear la función objetivo y las restricciones; por otro lado, las variables de decisión tienen su propia naturaleza numérica, las cuales se definen en el rango de existencia de variables el cual se hablará a detalle más adelante.

Algunos ejemplos de variables de decisión serían los siguientes:

- Cantidad de productos del producto A
- Precio del producto A
- Costo del producto A
- Decisión de construir un hospital



## Parámetros

Son los valores numéricos fijos que se emplearán en la formulación del modelo matemático. Estos valores pueden usarse al costado de una variable para dar a entender proporcionalidad, precio, costo, entre otros; por otro lado, pueden usarse para dar a entender limitaciones en el uso de recursos o rango en donde se desea que se encuentre la variable de decisión, es el valor que se encuentra en el lado derecho de la desigualdad.

Las restricciones son las condiciones que debe cumplir la solución sin importar si es de manera empírica o por investigación operativa; pueden ser inecuaciones o ecuaciones. Son los límites que tendrán los recursos para el empleo de ellos en la operación a realizar. El valor limitante debe estar al lado derecho y las variables deben estar en el lado izquierdo, es la normativa. Algunos ejemplos de restricciones serían los siguientes:

- $X_i \leq 200$
- $A_i \leq 200$  ,  $A_i \geq 50$
- $C = 1$

Para el primero la variable denota la cantidad de productos y la limitante es que no puede producir más de 200 productos en total. En el segundo la variable de decisión es la cantidad de grados Celsius que puede soportar un metal en una operación de forjado sin que se resquebraje, como se muestra está en el rango de 50 a 200 grados C°. Por último, la variable expresa la asignación del tractor tipo C en el proyecto de agricultura, porque previamente ya se realizó un contrato de alquiler y se debía utilizar para no caer en un costo innecesario.

## Rango de existencia de las variables de decisión

El fin del rango de existencia es describir la naturaleza de las variables de decisión; se utilizan inecuaciones para definir el rango, es muy importante para poder dar una solución correcta. Hay que mencionar que no pueden tomar valores negativos las variables de decisión. Las naturalezas que puede adoptar son las siguientes:

- Naturales mayores o iguales a 0
- Enteros mayores o iguales a 0
- Binarios

### 1.1.3. Pasos para la construcción de modelos matemáticos

Winston (2015) propone construir el modelo matemático de manera adecuada con los siguientes pasos que se muestran a continuación:

### **Paso 1: Plantear el problema:**

Se debe conocer la empresa para poder plantear cual es la necesidad y definir cuál es la meta del proyecto de optimización. La necesidad de plantearía en la función objetivo a partir de las variables de decisión; sin embargo, no se podrá realizar sin previamente haber procedido a realizar el paso 2.

### **Paso 2: Observar el sistema**

Ya definida la necesidad en el paso previo, se debe entender todo el sistema para poder definir las variables en la realidad que la afecta. Ya comprendido todo el sistema de cómo se interrelacionan las variables se podrá pasar al siguiente paso que sería la formulación del modelo matemático.

### **Paso 3: Formular un modelo matemático.**

Conociendo cómo se corresponden las variables se decidirán cuáles son de relevancia y tienen una relación correlación relevante con la necesidad que se planteó en el paso 1, y las escogidas se convertirán en las variables de decisión que se usarán en el modelo. En este punto ya se debe plantear la función objetivo, restricciones, variables de decisión, rango de existencia de las variables y los parámetros que se utilizarán para definir de manera adecuada a las variables de decisión y los límites que se colocarán en las restricciones.

### **Paso 4: Verificar el modelo y usarlo para pronosticar una realidad**

Habiendo planteado el modelo previamente, se revisará minuciosamente para corroborar si representa a la realidad exactamente. Es uno de los puntos más importantes porque luego se resolverá y se podría llegar a una respuesta errónea y no por el método utilizado para resolver, sino porque no se planteó de manera adecuada, por eso se debe tener bastante cuidado.

### **Paso 5: Seleccionar una opción adecuada**

Realizado por el método adecuado para el tipo de problema se llegará a una respuesta que sería si se realiza de manera adecuada la óptima. Se debe tener en cuenta que no necesariamente hay una sola respuesta óptima, sino que puede haber más, sería el caso de soluciones múltiples. Además, pueden darse casos que no haya factibilidad debido a que hubo conflictos entre las restricciones; no acotamiento, es cuando no está limitado bien el problema, serían más restricciones; y, por último, el caso llamado degenerado, es cuando existen más restricciones que cantidad de variables.

### **Paso 6: Presentar los resultados**

Luego de haber realizado la metodología escogida y tener los resultados, se procede a la interpretación de las variables de decisión.

#### **1.1.4. Formas de solucionar el problema**

De las maneras que existen para resolver problemas como:

- Metodología gráfica
- Algoritmos
- *Solvers*

Se explicará sobre cómo se puede implementar con el programa con nombre en inglés llamado “*A mathematical programming Language*” (AMPL). El programa según su misma página web se enfoca en el soporte para el modelamiento de modelos matemáticos de optimización, testeo, despliegue y mantenimiento. Además, según una revista llamada “*Comparison of Integer Programming (IP) Solvers for Automated Test Assembly (ATA)*”, hace mención que es un programa que trabaja con el lenguaje de multisolucionadores, lo que significa que puede redactar el modelo de programación y puede cambiar de solucionador sin necesidad de alterar el modelado.

Al ser un programa de modelamiento, tiene su propio lenguaje de programación donde se pueden plantear todos los puntos que demanda un modelo matemático de optimización: función objetivo, restricciones, variables de decisión, parámetros y rangos de existencias. El programa puede resolver problemas lineales y no lineales; para lo lineales, que se usarán para esta problemática, son CPLEX, Gurobi y Xpress; para los no lineales, CONOPT, Ipopt, KNITRO, MINOS y SNOPT; y para los mixtos con Bonmin, Couenne y KNITRO. Se realizó un manual para la comprensión de AMPL (Ver Anexo N°1)

En este caso, se explicará sobre los solucionadores para problemas lineales ya que estos se emplearán para la resolución del problema. De acuerdo a Donoghue (2015), se detallarán sobre ellos.

#### **CPLEX**

Es un solucionador para el tipo de problema lineal, con ecuaciones de primer grado, y tiene el lenguaje de Optimization programming language(OPL) que por primera vez apareció en el libro que publicó Pascan Van Hentenrick llamado “*The OPL Optimization Programming Language*” en 1999. Más adelante IBM se hace dueño de la tecnología y lo fusiona con el lenguaje de Java. Actualmente permite realizar programación lineal, entera mixta y

cuadrática. Tiene un muy buen desenvolvimiento; sin embargo, su precio es alto lo que restringe en parte su uso.

### **Gurobi**

Se dio a conocer en el mercado en el 2009, lo que lo hace relativamente nuevo y el cual se enfoca en solucionar problemas donde se usa programación lineal entera mixta. Ofrece una versión académica para estudiantes y universitarios. Por otro lado, su mercado meta va para el mismo que el CPLEX y es el solucionador por defecto de la versión gratuita del solucionador de la fundación de Microsoft.

### **Xpress**

Se ha realizado en la organización financiera creada por Fair-Isaac, según su misma página web hace mención que puede resolver problemas lineales, entero mixtos, no lineales y estocásticos. Se encuentra enfocado en la resolución de problemas de organizaciones y tiene un costo asequible para el mercado con un buen rendimiento.

## **1.1.5. Programación entera**

Según con Hillier(2001), la programación entera se divide en tipos de variables de decisión: la programación binaria, la cual se utiliza en los tipos de problemas que se requiere un valor booleano de decisión que usualmente 1 es valor afirmativo para que se active la variable con que se está relacionando o valor 0 para que no se active en la ecuación lineal la variable o con la que se está relacionando, y el otro tipo de variable de decisión podría tomar los valores de 0 y los enteros positivos. Por otro lado, con estas variables también se podrían utilizar para realizar una programación entera mixta, la cual consta de los dos tipos de variables: enteras y fraccionarios exactos.


Con estos posibles tipos de variables de decisión enteras salen diversos tipos de problemas que se pueden aplicar ante diversas problemáticas. A continuación, se mostrarán ejemplos de algunos tipos de ejercicios. A continuación, se mostrarán ejemplos de programación entera.

## **1.1.6. Programación entera binaria**

### **Presupuesto de capital con propuestas de inversión fijas**

Se modifica un ejemplo de Winston (2001) en el cual se tiene un monto para poder invertir en un negocio de un ejemplo previo, se desea saber si se debe invertir un monto fijo en un cierto tipo de instalación (fábrica o almacén en un cierto sitio (Los Ángeles o San Francisco)).

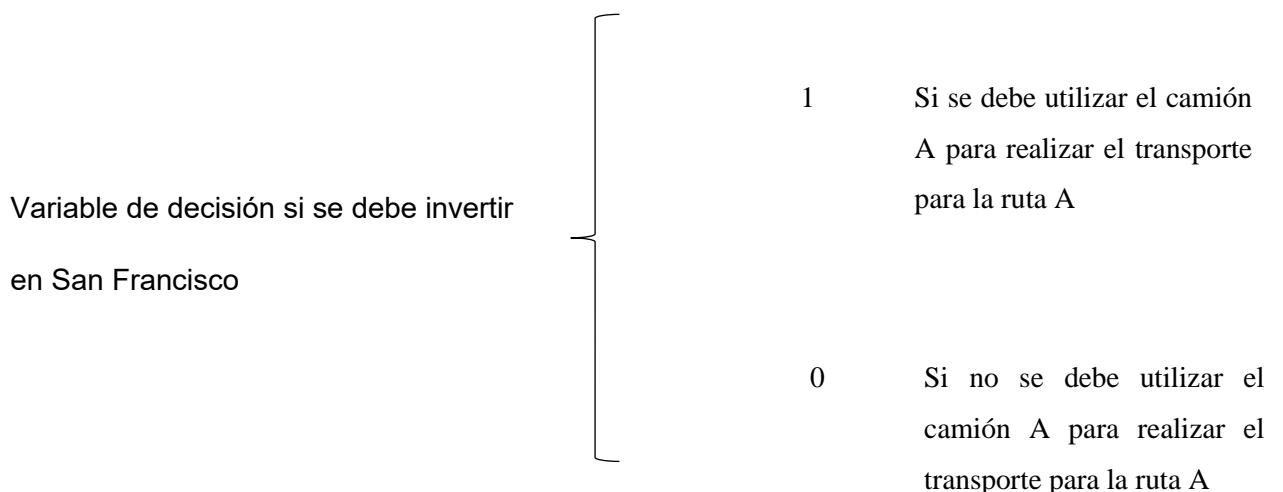
Al ser la decisión de inversión un tipo de problemática booleana se opta por el uso de una variable de decisión entera, pero de tipo binaria, para que sea afirmativo el uso de la inversión o negación para su uso (p. 580). Se planteará visualmente a continuación cómo sería la estructura de la variable.



Como se puede ver previamente, la variable de decisión de tipo binaria es para realizar decisiones.

### Despacho de envíos

Se modifica un ejemplo de Hillier (2001) para que se pueda llegar a una mejor comprensión de la usabilidad de este tipo de variable. Se plantea que existe una red de producción y distribución donde se realizan decisiones operativas diarias acerca de cómo realizar los envíos por medio de camiones por medio de diferentes rutas. Se desea saber qué camión utilizar dependiendo de los gastos de combustible que cada uno tiene como característica propia del modelo de vehículo dependiendo del camino a tomar. (p. 585).

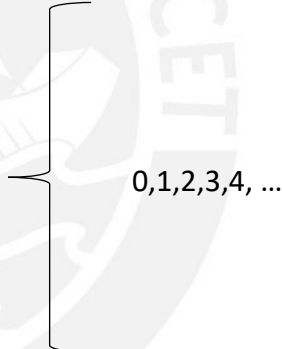


Como se aprecia previamente, se utilizan también las variables para poder asignar un recurso a alguna actividad que la problemática misma plantea, es un tipo de decisión más compleja que una booleana, sino que ya crea una vinculación entre dos variables.

### 1.1.7. Programación entera positiva

Un problema demostrativo para ejemplificar este tipo de programación entera vendría a ser el siguiente. Existe una compañía en la cual hay que realizar un proyecto donde una parte de ese mismo requiere saber cuántas personas se requieren para la construcción de un edificio. Con este se llegará a que se pueda cumplir con el periodo de tiempo planteado por los clientes.

En este caso como la variable de decisión son la cantidad de personas que se requerirán en el proyecto, son enteras y no fraccionarias porque no existe medias personas o cualquier fraccionario. Debido a la naturaleza del recurso se define como una variable de decisión entera positiva contando el cero.

Variable de decisión de la cantidad de personas para el proyecto.  0,1,2,3,4, ...

Como se puede observar en el ejemplo anterior, cualquier variable cuya naturaleza deba ser entera porque es indivisible y positiva como, por ejemplo: personas, botellas, paquetes, vehículos, entre otras. Toma como nombre variable de decisión entera.

### 1.1.8. Programación entera mixta

Es una combinación de variables de decisión enteras y continuas. El tipo de problema es más complejo que los mostrados anteriormente, el caso de continuas es similar a la entera positiva solo que con números continuos. Un ejemplo sería que una empresa tiene una necesidad de cuántos camiones se necesitan para poder realizar el proyecto de traslado ya con una ruta predefinida con el mínimo costo. Sus restricciones serían que tienen camiones limitados, pero con la posibilidad de poder alquilar, tienes 5 proveedores de gasolina y cada uno tiene un costo diferente del combustible y una cantidad máxima de entrega

más un costo de envío de la gasolina a la empresa determinado por un rango de combustible pedido.

Las variables de decisión enteras serían los camiones y las variables de activación para que se pida a un proveedor, y las variables de decisión continuas serían la cantidad de gasolina requerida en total. La cantidad máxima de entrega es una restricción de valor continua; la cantidad máxima de camiones y el costo en función de un rango son restricciones con valor entero.

## 1.2. Cadena de Suministro o Supply Chain

Es importante tener comprendido cómo será la organización de la cadena de suministro ya que va muy relacionado con el producto; de sus materias primas, el proceso, cómo se distribuye y cómo llega al cliente. En los siguientes puntos se explicará qué es una cadena de suministro y qué abarca.

### 1.2.1. Definición

Según Ronal Ballou en su libro “Logística: administración de la cadena de suministro (2014)” da una definición de Cadena de Suministro (*Supply Chain* en inglés), la cual es la siguiente: “La cadena de suministro abarca todas las actividades relacionadas al flujo, transformación de bienes, desde la etapa básica de materia primera (extracción), hasta el usuario o consumidor final, así como los flujos de información relacionados. Los materiales y la información relacionada fluyen en sentido ascendente y/o descendente en la cadena de suministro.” A continuación, se muestra una imagen donde se puede tener un panorama de alto nivel para comprender sobre qué abarca la cadena de suministro.

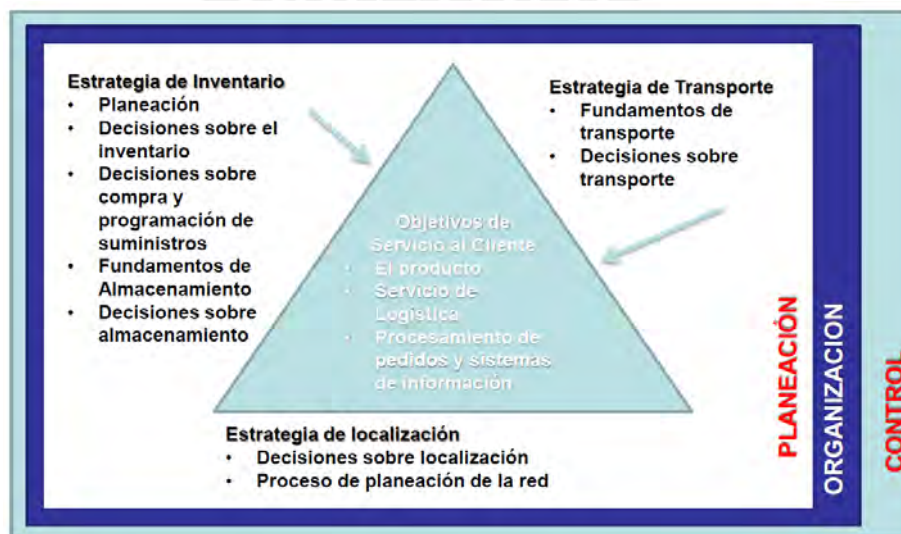


Figura 1 : Panorama de la cadena de suministro

Fuente: Administración de la Cadena de Suministro- Ronald Ballou - Logística, Administración de la Cadena de Suministro

La definición empleada es de alto nivel; sin embargo, como se puede ver en la siguiente imagen, el alcance de la cadena de suministro de la empresa puede variar dependiendo de sus actividades.

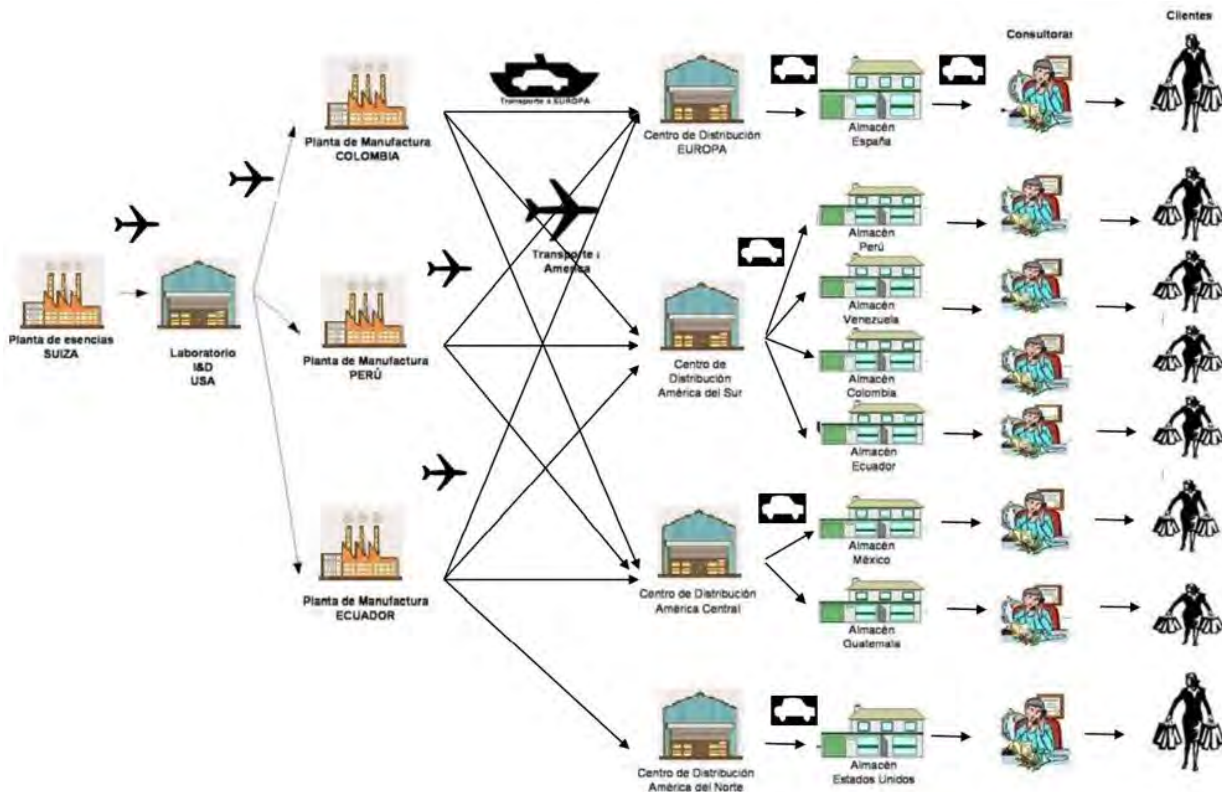


Figura 2: Ejemplo de panorama parcial de una empresa de cosméticos

Fuente: Planeamiento y control de operaciones PUCP

No va desde la materia primaria, sino se “recorta” la cadena de suministro porque no es el alcance de la empresa saber desde el inicio primario de la materia prima, de eso se preocupan sus proveedores. Por lo tanto, la cadena de suministro abarca desde la primera etapa hasta la etapa final que es la entrega al cliente, pero se puede reducir el alcance si se enfoca en una empresa y su interés.

Según Elkington (1998) sugieren que hay tres pilares de sustentabilidad o sostenibilidad que deber ser cuidadas dentro de una empresa, ya que si no se tiene los cuidados necesarios llegaría a una cadena de suministros insustentable; las tres dimensiones son: social, económico y ambiental. Seuring and Müller (2008) agrega que los pilares son derivados de los requerimientos de los consumidores y *stakeholders*.



## **1.2.1. Los tres pilares de la sustentabilidad**

### **Social**

Se enfoca más en la etapa primaria, inicial, de la cadena de suministro. En la inclusión de los trabajadores primarios para que puedan mejorar en su producción y puedan dar mejores productos; al mismo tiempo, poder perdurar en el tiempo y no tengan problemas. Claramente esto le da a la empresa una seguridad en provisión de materia prima, una buena relación con sus proveedores e incluso genera más trabajo en la comunidad cercana.

### **Ambiental**

Toma en cuenta el cuidado del medio ambiente, se pueden utilizar varias métricas, por ejemplo: huella de carbono, gasto de comida, calidad de agua, calidad de comida, seguridad, calidad del aire, entre otros. Los aspectos beneficiosos serían que, si están cerca de un área agricultora, las plantas darán un fruto mejor, mayor producción, etc. Si no está cerca de un área agricultora o ganadera, es posible que no se vean directamente sus efectos negativos, pero igual existen. Además, que sea amigable con el medio ambiente permite tener una imagen agradable ante la sociedad, que abarca a sus clientes, y esto se podría extender a sus proveedores, lo cual también conlleva a una mejor relación con ellos.

### **Económica**

Tiene como meta la reducción sobre los costos, esto abarca en la forma de soluciones de problemas o implementaciones de nuevos proyectos. Esto permite una sustentabilidad a largo plazo con un flujo de caja sólido.

## **1.3. Analítica**

En estos días hay una nueva corriente en las empresas que se enfoca en las decisiones en función de los datos, en inglés se le denomina a este nuevo comportamiento de empresas *data-driven*. Si bien hay decisiones que se toman por experiencia de la persona a cargo, ya no basta solo la "intuición" o experiencia de la persona, tiene que ser sustentados con la información a partir de los datos recolectados, ya que con un mejor análisis de los datos se reduce el riesgo a escoger una opción no óptima o hasta errónea. A continuación, se detallará acerca de qué es la analítica y qué abarca.

### **1.3.1. Definición**

Como su nombre permite intuir a qué se refiere, es el análisis de los datos recolectados en la primera etapa de la analítica. Actualmente está tomando bastante fuerza en las

empresas por la corriente de forma de trabajo *data-driven*. El proceso para llegar a la “sabiduría” como empresa tiene tres etapas previas, se puede ver en la imagen siguiente.



Figura 3: Pirámide del conocimiento

Fuente: Glogster (2015)

La parte donde se enfoca la analítica es todo el camino hasta llegar el conocimiento, todo antes de la implementación. En ese camino se dividen en 4 puntos, aunque usualmente en la teoría se junta la parte descriptiva con analítica de diagnóstico, en este trabajo se separarán según el curso llamado “*Customer Analytics*” de la universidad de Wharton brindado por Coursera; asimismo las definiciones brindadas por el curso serán desarrolladas en base a ellas. Están ordenados de forma secuencial, se muestra una imagen para que se entienda el flujo de trabajo.

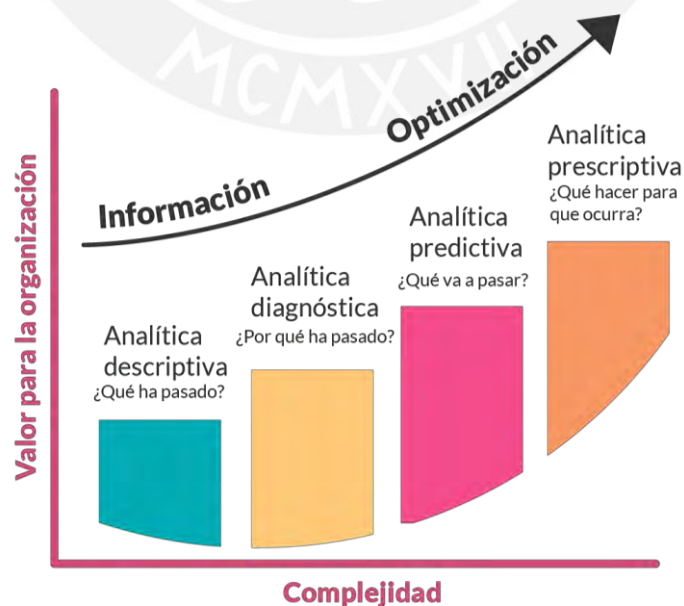


Figura 4: Etapas de analítica

Fuente: Pontificia Universidad Católica de Chile

### **1.3.2. Etapas de la analítica**

#### **Descriptiva**

Es la primera etapa de la analítica, no se está considerando la parte previa de extracción, tratamiento y limpieza de datos, ya que es un paso previo que prepara la data para ser apta para el análisis, se le conoce como ETL por sus siglas en inglés. Volviendo a la analítica descriptiva, se enfoca en comprender “¿qué ha pasado?”, ya que trabaja con data histórica o recolectada. Trabaja juntamente con la estadística descriptiva y gráficos que puedan hacer visibles las tendencias o comportamientos de los datos fácilmente.

La estadística descriptiva tiene como fin la recopilación, clasificación, presentación y descripción según el autor Celestino García Oré en su libro “Estadística descriptiva y probabilidades para ingenieros”, además tiene diversas herramientas que tienen con fin lo mencionado, algunas son: la media, mediana, modelos estadísticos, mediciones de variación, cuartiles, entre otros. Por el lado de los gráficos, se usan gráfico de líneas, gráfico de puntos, histogramas, gráfico de barras, diagrama de cajas, diagrama de violín, gráficos empleando la teoría de principales componentes de análisis de estadística descriptiva juntamente con dendogramas, métodos de agrupación por k – medias, entre otros.

Como se puede ver hay una gran variedad de herramientas para poder responder la pregunta inicial. El objetivo de esta etapa es poder tener el panorama claro para poder elegir qué herramientas se podrán utilizar más adelante y cómo tratar a los datos.

#### **Analítica de diagnóstico**

Como se ha comentado previamente, se podría incluir dentro de la etapa descriptiva, es el análisis luego de usar las herramientas descriptivas. Se complementa con la información histórica que está afuera de los datos, pueden ser eventos sociales, leyes decretadas, fechas, anomalías climáticas, entre otros. Esta etapa es donde se requiere la habilidad blanda de capacidad de análisis del equipo.

#### **Predictiva**

En esta etapa ya luego de analizar y comprender el “¿Qué ha pasado?” y el “¿Por qué ha pasado?” se plantea un nuevo objetivo “¿Qué va a pasar?”. El nuevo objetivo planteado por la empresa es enfocado en la reducción de riesgo y mayor rentabilidad posible, si se sabe claramente cuál será la respuesta del mercado, suponiendo que es una empresa que lucra con productos, al plantear una nueva línea de productos o un nuevo producto. Se podrá entender de mejor manera en cuáles sectores tendrá gran acogida, en cuáles sectores no valdrá la pena invertir, entre otras preguntas del negocio. Aún estamos llegando

a la etapa de información, esta es la etapa previa a la de conocimiento. Algunas herramientas predictivas serían: regresión lineal, regresión logística, árboles de decisión, reglas de asociación, redes neuronales, análisis de sentimiento en redes, series temporales, entre otros.

En esta etapa coge gran fuerza el aprendizaje automático o *Machine Learning*, ya que tiene herramientas muy potentes que trabajan con algoritmos que permiten enfocar dar una respuesta al futuro comportamiento de la entidad o variable según la data, luego del *ETL*. Por otro lado, también entran los modelos estadísticos y pruebas de hipótesis que permiten poder responder con cuánta significancia es fiable la respuesta de salida.

Como en la primera etapa, descriptiva, también se utilizarán gráficos enfocados para mostrar los datos de salidas u *outputs* porque si bien el algoritmo puede dar respuestas posibles a comportamientos futuros; es matemática, el ser humano adquiere de mejor manera información de manera visual ya que acorta el proceso de entender un concepto, no requiere que se cree una imagen mental ya que el gráfico al frente. Es una buena práctica saber acerca de *storytelling* cuando se utilicen gráficos, porque un mal gráfico puede llegar a una idea equivocada, pero definir eso escapa del alcance del trabajo.

### **Prescriptiva**

Luego de la etapa predictiva, comienza una etapa parecida a la de analítica de diagnóstico. Es la prescriptiva, en esta etapa ya luego de tener una información clara de cuáles son los comportamientos posibles de los clientes, si fuera una empresa que vende productos, si se realiza una acción; ahora se debe ver el “¿Cómo?”. Se debe analizar cuáles son las restricciones del proyecto, tiempo de realización, puestos necesarios, cuándo iniciar, entre otros puntos importantes para decidir.

Aquí entra la toma de decisiones no estructuradas, hay tres tipos de toma de decisiones: estructurada, semi estructurada y no estructurada. La estructurada es cuando es una decisión rutinaria y repetitiva; la no estructurada es por juicio, experiencia, criterio, evaluación y profundización para resolver un problema; y la semi estructurada involucra una combinación de las dos mencionadas previamente. Las decisiones no estructuradas comienzan a aparecer en la empresa a partir de la gerencia media para arriba.

### **1.3.3. Lenguajes de programación**

Cuando se habla de analítica, es necesario comentar de las herramientas que se tienen que conocer para poder realizar un análisis efectivo para poder lograr las mejores decisiones al tiempo correcto, no después del evento. Algunos ejemplos son SAS, Python, R, AWS, etc. En este documento se explicará un poco de los lenguajes de libre acceso R

y Python. Se detallará adicionalmente algunos detalles de cada lenguaje y sus ventajas como desventajas según una publicación de DataCamp llamada “*Data Science Wars*”.

## Python

Es un lenguaje creado en 1991 por Guido Van Rossum que se enfoca en la productividad y la facilidad de entender el código, es usado mayormente por programadores que quieren realizar análisis o desarrolladores que desean ir por el campo de *Data Science*. Al tener una facilidad para la comprensión de su código es más fácil implementarlo en las empresas, los programadores que no conocen del lenguaje lo aprender en corto tiempo. Es un programa de muy rápida ejecución cuando halla gran cantidad de datos y muy popular dentro de la comunidad. Sin embargo, cabe detallar que es un lenguaje de alto nivel multipropósito, pero su orientación va más por el lado de desarrollo web y programación.



Figura 5: Logo de Python

Fuente: Escuela de Python

## R

Fue creado por Ross Ihaka y Robert Gentleman en 1995, está enfocado en dar un amigable análisis de datos, estadísticos y modelos gráficos. Es usado mayormente por académicos e investigadores, una de las razones es su enfoque y que la codificación es más corta para poder emplear alguna herramienta que otorgan los paquetes. Si bien es corta su programación y enfocado al análisis; está hecho por estadísticos, lo que implica que su codificación no es tan fácil de comprender como la de Python. Python es más veloz en procesamiento; sin embargo, R tiene paquetes que aumentan la velocidad, por ejemplo: pqR, renjn, FastR, Riposte, RevoScaleR y Foreach. Por otro lado, tiene una gran capacidad de visualizaciones con gran entendimiento y eficiencia.

Para el análisis que está más adelante del documento, se optó por R por su capacidad de análisis y corta codificación para poder utilizar las herramientas para poder realizar un análisis estadístico con menos rango de error.



Figura 6: Logo de R  
Fuente: Mapping GIS

#### 1.3.4. Principales componentes de análisis – PCA

Se dará una explicación acerca del método de reducción dimensional PCA (por sus siglas en inglés *Principal Component Analysis*) del libro *Practical Guide to Principal Component methods in R* del auto Albokadle Kassambara del año 2017 para que se pueda comprender claramente su uso en este trabajo. Se utiliza para reducir la cantidad de variables a una menor para que sea más fácil poder realizar visualizaciones tratando de perder lo mínimo en capacidad de explicación de todas las variables. En otras palabras, si se tuviera 30 variables y se quisiera ver su comportamiento sería muy complicado; por medio del procedimiento matemático se puede reducir a 2 variables pero que pueden explicar el 78% del comportamiento conjunto de todas las variables. Su alcance sería que se pueden ver entidades que se comportan de manera parecida de un vistazo en un gráfico.

Es una gran ayuda visual, está en la etapa descriptiva porque más allá de su dificultad, sigue siendo una herramienta para poder describir de mejor manera los datos existentes. A continuación, se mostrará una imagen donde se puede ver la “familia” de métodos de principales componentes, ya que el PCA es uno de ellos y que permite hacer las transformaciones cuando la data es cuantitativa.

## Principal Component Methods

Summarizing & Visualizing Multivariate Data

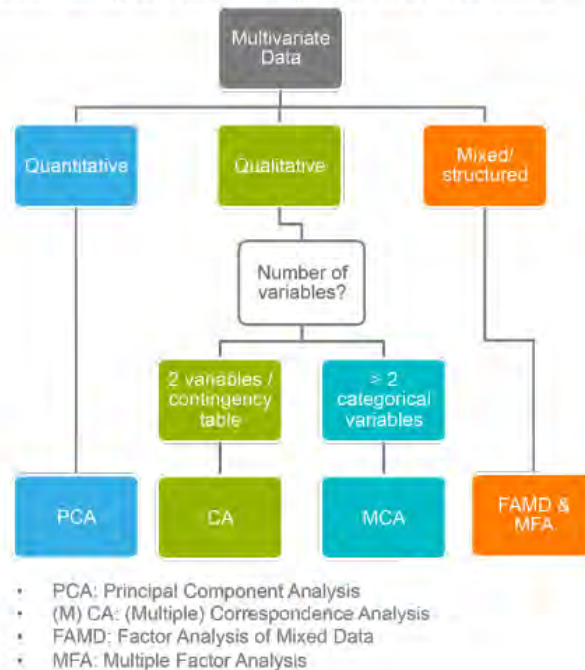


Figura 7: Métodos de principales componentes

Fuente: Practical Guide to Principal Component methods in R

### Definición

La definición se basará en un libro llamado “*Practical Guide to Principal Component Methods in R*” escrito por Alboukadel Kassambara. Da una explicación clara para comprender la idea matemática para poder entender lo que logra el PCA, no se busca una detallada definición sino una que permita entender qué realiza.

Se basa en algebra lineal, busca hacer una transformación orientando los ejes a donde pueda reducirse lo máximo posible su varianza, el procedimiento primero busca realizar un eje de principal componente, luego de que se realiza, busca hacer el otro siendo este ortogonal al primero, luego un tercero que es ortogonal a los otros dos y así hasta la cantidad  $n-1$  como máximo de ejes, siendo  $n$  la cantidad de variables al inicio.

En el gráfico 1A se utiliza las variables “x” e “y” en un gráfico de puntos, se puede ver que en color rojo está el primer Principal Componente y el azul es el segundo Principal Componente. El primero en línea a donde se direcciona la mayor varianza y el segundo busca explicar lo máximo posible la varianza que falta siendo ortogonal al primero. En el gráfico 1B se muestran los puntos, pero viéndolos con los nuevos ejes, se nota mucho menos “ruidoso” el gráfico.

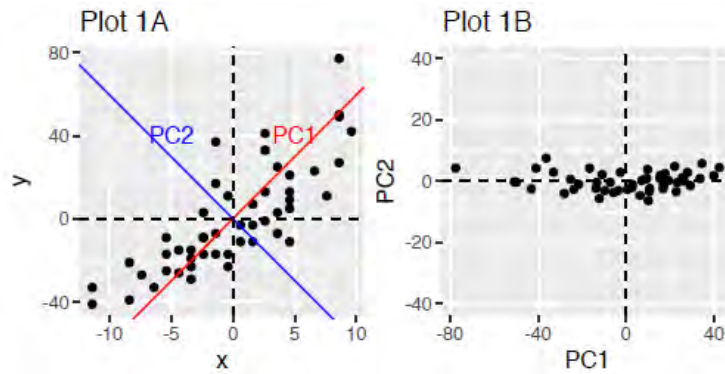


Figura 8: Ejemplo gráfico de cambio de ejes

Fuente: Practical Guide to Principal Component methods in R

Cuando hay menos ruido entre las variables los primeros componentes explicarán una mayor cantidad de varianza. En el siguiente gráfico el de la izquierda tiene poca redundancia y el de la derecha alta, prácticamente en el segundo con un eje de 45 grados explica en gran manera el comportamiento de las variables.




Figura 9: Ejemplo gráfico de redundancia de los datos

Fuente: Practical Guide to Principal Component methods in R

Acerca de los otros: CA, MCA, FAMD y MFA, tienen un comportamiento similar, en el caso de las variables categóricas también se halla su variabilidad en función de otras mediciones.

### 1.3.5. Dendograma

Es un gran complemento para cualquiera de los métodos mencionados previamente, ya que todos buscan hallar “¿Cuán diferentes son las entidades la una de la otra?”. Se utiliza para agrupar en pares según una estimación de la “distancia” de las entidades según la otra. Las más cercanas serán agrupadas primero, se podría decir que el grupo formado se toma como una entidad nueva que reemplaza a las otras dos y se repite la revisión de cuáles entidades son las más cercanas. Si el grupo tiene un punto cercano se le adiciona una entidad más, si otros dos puntos están más cercados se forma otro grupo y así gradualmente hasta que todas sean agrupadas en un solo grupo.



A continuación, se mostrará una imagen para que se entienda la idea gráficamente.




Figura 10: Agrupamiento por distancia para el dendograma

Fuente: DataCamp - Analysis cluster in R

El procedimiento con que se agrupó para generar la imagen anterior fue de la siguiente manera: primero se agrupó el 1 y 2, luego se juntaron el 5 con el 6, el conjunto del 1 y el 2 se agrupó con el 4 y finalmente el conjunto del 1,2 y 4 se agrupó con el 3. Más adelante se muestra un dendograma tomando estas agrupaciones para ir construyéndose.

Hay 3 métodos para calcular la distancia: enlace completo, enlace único y enlace promedio. Una explicación a alto nivel sería que el completo contrasta las máximas distancias entre dos conjuntos, el único busca la mínima distancia entre los dos grupos y el promedio busca la distancia promedio entre los dos grupos. Realizando estas agrupaciones se realiza el gráfico y se va armando de abajo para arriba.




Figura 11: Dendograma

Fuente: DataCamp - Analysis cluster in R

El uso del dendograma más los principales componentes se le conoce como Agrupamiento Jerárquico con Principales Componentes (HCPC por sus sigla en inglés). Es una herramienta muy potente para el análisis visual descriptivo y permite tener una idea de posibles grupos con comportamientos similares.

### 1.3.6. Árbol de decisión

#### Definición

Es un tipo de algoritmo que se utiliza en la etapa predictiva, dentro del aprendizaje automático hay dos tipos de aprendizaje: supervisado y no supervisado. El árbol de decisión está en la categoría de supervisado debido a que los supervisados tienen el valor *target*, el “target” es lo que se desea predecir, mientras que los no supervisados no tienen ese valor y buscan explicar los datos en función de los mismos, por ejemplo el tema anterior HCPC que en función de las distancias entre sus variables agrupan conjunto de datos. La definición previa y las próximas serían basadas en el curso “*Tree-Based Models in R*” dictado por Gabriela de Queiroz *Data Scientist* y fundadora de R-Ladies y Erin L. *Chief Machine Learning Scientist* en H2O.ai.

#### Modelos

Hay varios modelos de árboles de decisión: regresión, clasificación, en bolsa (*Bagged Trees*), bosques aleatorios (*Random Forests*), entre otros. Los dos primeros mencionados son muy similares, solo que el tipo de datos de la variable *target* es diferente, el de regresión tiene un valor numérico como *target* y el de clasificación un carácter.

El procedimiento del algoritmo del árbol va a ir generando divisiones de la data en función a una restricción. Por ejemplo: personas mayores a 50 años, los datos que cumplan con la restricción se les agrupará con los que cumplan, y los que no cumplan irán con el grupo que no cumpla. Sin embargo, no solamente es separar por separar, es buscar en el caso de los categóricos la mayor “pureza” de los datos; algunos de las herramientas para medirla son : gini, entropía y chi-cuadrado . La pureza es que luego de separar los grupos y determinar hasta qué nivel el árbol se seguirá diviendo, el grupo debe tener un gran porcentaje del mismo tipo del *target* o si es numérico, debe tener la menor varianza posible o apoyarse en una prueba F. En la siguiente imagen se puede ver el intento de separación por tipo de *target*.




Figura 12: Límites de decisión en árbol de decisión

Fuente: Queiroz,G. (2020)

### Datos de entrenamiento y de prueba

Cuando se trabaja con aprendizaje supervisado, es necesario hacer “entrenar” al modelo con data previa para “aprenda” y pueda predecir eficientemente con nuevos datos. También existe datos de validación, los cuales son antes del de prueba final; sin embargo, el más usado son estos dos mencionados en el subtítulo. Lo más común es que el 80% de los datos sean usados para el entrenamiento y el 20% restante para la prueba del modelo con nueva data que no haya tocado. Los porcentajes pueden variar dependiendo de cuánta data se tiene, pero no se aleja mucho de los valores mencionados.



Figura 13: Recomendación de porcentaje en conjunto de entrenamiento y de prueba

Fuente: Queiroz,G. (2020)

Es sumamente importante que la data recolectada para cada conjunto sea de manera aleatoria. Si se deseara hacer para una serie de tiempo se tomaría un rango de fechas con la misma proporción, si se tuviera 10 años, los últimos 2 años serían para el test y lo 8 anteriores serían de entrenamiento.

### Partes del árbol

Se mostrará brevemente las partes de los árboles, y para tener una idea de por qué se llaman así. En la siguiente los nodos finales son las hojas, los que están entre el primero y las hojas son los nodos intermedios y el primero sería el nodo raíz. Además, siempre si la entidad cumple con la restricción irá para la izquierda y si no a la derecha.

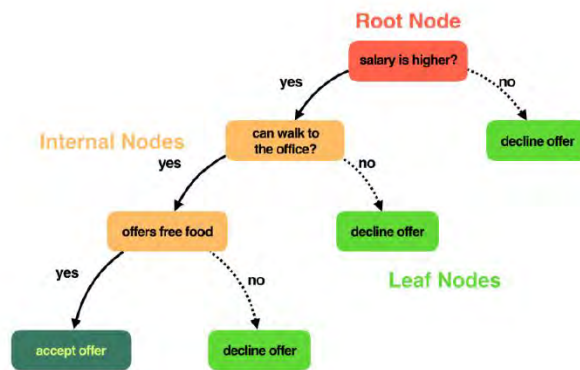


Figura 14: Explicación de elementos de árbol de decisión

Fuente: Queiroz,G. (2020)

## Poda

Se debe tener cuidado con los árboles de decisión, si bien son herramientas muy potentes, son vulnerables a que el error vaya aumentando mientras más hojas existan, sería un tipo de sobreajuste. Si bien se tiene una data de entrenamiento y se irá reduciendo el error, en data nueva e inclusive en la de validación, aumentará el error gradualmente. A continuación, se muestra una imagen que explica visualmente donde se debería hacer la poda, el cual es en el mínimo valor de error hallado en la data de validación.

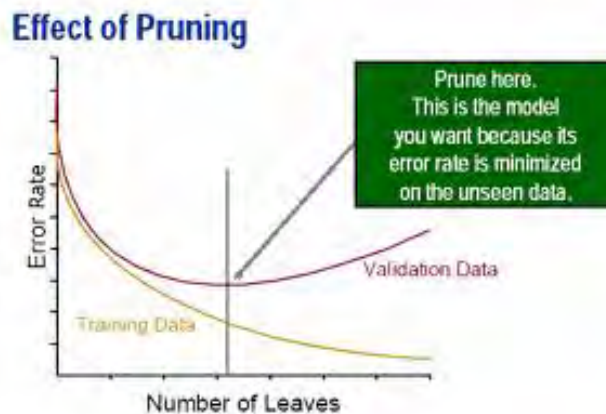


Figura 15: Efectos de la poda

Fuente: Queiroz,G. (2020)

## Evaluación del modelo

Hay diversas maneras de poder ver la eficiencia del modelo, las herramientas dependerán del tipo de dato que tiene el *target*. Si fuese categórico, se usaría una matriz de confusión la cual tiene muchos indicadores a partir de la misma tabla, lo cual se detallará próximamente. En el caso que fuese numérico se emplearía el error absoluto promedio

(MAE por sus siglas en ingles *Mean Absolute Error*) o la raíz cuadrada del error medio (RMSE por sus siglas en ingles *Root Mean Square Error*), El RMSE castiga los errores grandes con más dureza que MAE.

### 1.3.7. Tabla de confusión

Como se ha mencionado previamente, se utiliza para valores categórico. Se contrasta los valores reales vs los predichos por el modelo. La siguiente imagen es una tabla de confusión.

		Actual	
		SI	NO
Predecido	SI	VERDADEROS POSITIVOS (TP)	FALSOS POSITIVOS (FP)
	NO	FALSOS NEGATIVOS (FN)	VERDADEROS NEGATIVOS (TN)

Figura 16: Matriz de confusión

Los cuadrados que están en rojo son los valores que no han concordado con los valores reales, los cuales serían representados por los actuales en la tabla, lo que está entre paréntesis es por sus siglas en ingles. Se busca tener lo mínimo posible de los FP y FN. A partir de la tabla salen métricas, por ejemplo: *accuracy*, *recall*, *precisión* y *F1-score*.

El *accuracy* se utiliza para tener un panorama de la proporción de los errados contrastando con el todo. Se muestra la métrica:

$$\frac{TP + TN}{TP + TN + FP + FN}$$

El *recall* se enfoca en mostrar cuán bien se están concluyendo los positivos buscando no concluyendo que es falso y en realidad sea verdadero. Por ejemplo, no se desea enviar a un paciente enfermo a casa, si se hiciera sería un FN, se busca maximizar el TP.

$$\frac{TP}{TP + FN}$$

La *precision* busca maximizar las predicciones correctas. Por ejemplo, cuando se busca detectar fraudes y no se desea incomodar a los clientes que no han hecho fraude.

$$\frac{TP}{TP + FP}$$

El *F1-score* es una media armónica entre *precisión* y *recall*. Es una métrica equilibrada entre pocos falsos positivos y pocos falsos negativos. Por ejemplo, se desea saber si una reserva de un hotel se cancelará o no. Se persigue el equilibrio entre reconocer cancelaciones y aplicar promociones a reservas que no se van a cancelar.

$$2 * \frac{Precision * Recall}{Precision + Recall}$$

### MAE y RMSE

Ambos son mediciones de error, el MAE se podría ver como un previo al RMSE, como se ha mencionado antes, el RMSE castiga mayor dureza a los errores grandes. A continuación, se muestran las fórmulas.

$$MAE = \frac{1}{n} \sum | \text{actual} - \text{predicción} |$$

$$RMSE = \sqrt{\frac{1}{n} \sum (\text{actual} - \text{predicción})^2}$$

### 1.3.7. Clustering

El *clustering* se encuentra en el área de aprendizaje no supervisado ya que en función de las variables evaluadas busca agrupaciones dentro de los registros brindados. Dentro se encuentran diversas formas agrupaciones como el k-medios, k-medioides, los dendogramas (que se explicó previamente), entre otros.

En este caso, se explicará k-medios según el libro "*Practical Guide to Cluster Analysis in R*" de Alboukadel Kassambara para que se comprenda uno de los casos más usados.

#### K-medios

El algoritmo comienza seleccionando la cantidad de grupos a crear (clusters) donde se crea la cantidad de puntos decididos al inicio en un lugar aleatorio con apoyo de las Principales Componentes de Análisis para tener todo en dos dimensiones por si hubieran más. Los puntos iniciales serán los centroides iniciales.

El algoritmo comienza su iteración al agrupar los “puntos” en los ejes más cercanos a cada centroide por medio de la distancia euclidiana, luego sea crea un nuevo centroide por grupo y se repite la agrupación de los otros puntos al centroide más cercano. La cantidad de iteraciones se puede decidir, pero en la práctica se suele colocar 50 repeticiones.

### Cantidad de clusters

La manera que utilizaremos en esta investigación será el método del codo, que por medio de la suma total de cuadrados de todos los *clusters*, se iteraría las posibles cantidades de *clusters*. En el gráfico se podrá visualizar un “codo” que se forma cuando la suma de cuadrados totales comienza a decrecer de una manera lineal. Se escoge ese punto debido a que es el de menor cantidad de *clusters* pero que tiene un nivel bajo en contraste de distorsión, ya que la suma de cuadrados mide cuán compacto están los puntos del centroide, valores mayores donde se encuentra el “codo” se tenderá a que se reduzca el error, pero el óptimo es donde está el “codo”.

A continuación, se mostrará un gráfico de ejemplo con el método del codo (*elbow method*).




Gráfico 1: Elbow Method

Fuente: Practical Guide to Cluster Analysis in R (2017)

## 1.4. Series de datos temporales

### 1.4.1. Introducción

Las series de datos temporales son una medición de un dato a través del tiempo. El tiempo se divide en periodos homogéneos para que sea consistente el análisis; los periodos pueden divididos por días, semanas, meses, años, etc. Su uso más común es el de pronósticos, se busca pronosticar a través del comportamiento histórico del dato. La elección del modelo se fundamenta con la estadística y la precisión que tendrá el modelo, se deberá tener varios modelos para contrastar entre ellos cuál es el mejor. Las definiciones serán a partir del curso “*Time Series Analysis*” brindada por David S. Matteson Profesor asociado en la universidad de Cornell y del curso “*Arima Models in R*” brindada

por David Stoffer profesor de estadística en la universidad de Pittsburgh, ambos brindados por medio de DataCamp

### 1.4.2. Ruido Blanco

El ruido blanco es la serie temporal base se podría decir, es una serie que la ecuación que la explica es la siguiente:

$$Y_t = c + u_t$$

Términos

$Y_t$  = Valor del dato en el tiempo t

$c$  = Constante que es la media en este caso

$u_t$  = término de error

El ruido blanco es una serie estacionaria porque no depende del valor del anterior periodo, además su media es constante al igual que su desviación estándar. Un ejemplo de una serie de ruido blanco con  $c=0$  se muestra en el gráfico.




Gráfico 2: Ruido blanco

### 1.4.3. Supuestos y tratamientos de datos

Todas las series que se verán a continuación deben llegar por medio de tratamiento de los datos a que la serie tenga la cualidad de estacionariedad. Estacionariedad implica que la serie tenga media y varianza constante (homocedasticidad). Se podría decir que llegue a



ser un ruido blanco para que sea analizable de manera fácil sin necesidad un modelo altamente complejo.

Al inicio la gran mayoría, por no decir todos, tendrán un comportamiento diferente, se requerirá realizar tratamiento como la diferencia con periodo “x” anterior, se usa cuando no muestra una media constante; y se aplicaría logaritmo a los datos cuando su varianza no es constante, es para homogeneizarla.

#### 1.4.4. Caminata Aleatoria

La Caminata Aleatoria es una serie temporal que no es estacionaria debido a que su valor en el tiempo “t” se ve influenciado por valor o valores pasados. Es más común que el Ruido Blanco; a continuación, se muestra la ecuación que lo explica.

$$Y_t = c + Y_{t-1} + u_t$$

Es importante saber que el ruido  $u_t$  tiene una media de 0 tiene el comportamiento de un Ruido Blanco. Por otro lado, requiere un  $Y_0$  como punto inicial para la simulación. Se mostrará un ejemplo de gráfica para ver su comportamiento.




Gráfico 3: Caminata aleatoria con  $c=0$

La gráfica previa  $c=0$ , lo cual hace que las fluctuaciones no sean tan bruscas o muy leves. Por ejemplo, el gráfico que sigue mostrará cuando  $c=1$  donde no hay variaciones notorias, sino bien suaves. Si fuera el caso de un  $c<0$  se volvería “bruscas” sus variaciones.




Gráfico 4: Caminata aleatoria con  $c=1$

Sin embargo, por muy interesante que sea esta serie, no es modelable sin antes hacer un tratamiento, el tratamiento sería hacer una diferencia y lograr que llegue a ser un ruido blanco.

$$Y_t - Y_{t-1} = c + Y_{t-1} - Y_{t-1} + u_t$$

$$\Delta Y = c + u_t$$

#### 1.4.4. ACF (*Auto-correlation Function*)

Permite identificar la dependencia en el componente Media Móvil (MA en sus siglas en ingles), se mostrará en los casos específicos del modelo cómo se identifica un modelo AR, MA o ARMA,ARIMA o SARIMA. Permite identificar el orden del componente MA para identificar el modelo. Un ejemplo del gráfico ACF se muestra a continuación.

#### 1.4.5. PACF (*Partial Auto-correlation Function*)

Ayuda a identificar la dependencia en el componente Autorregresivo (AR en sus siglas en ingles), se mostrará en los casos específicos del modelo cómo se identifica un modelo AR,MA o ARMA,ARIMA o SARIMA. Además, ayuda a identificar el orden del componente AR para saber qué modelo es.

### 1.4.6. Autorregresivo (AR)

El modelo autorregresivo tiene una variación conforme a la caminata aleatoria en su ecuación. Se muestra a continuación la ecuación de un AR con autocorrelación del valor de un periodo previo.

$$Y_t = c + \phi * Y_{t-1} + u_t$$

La versión de la ecuación centrada en la media sería la siguiente.

$$Y_t - \mu = \phi * (Y_{t-1} - \mu) + \varepsilon_t$$

Términos

$\varepsilon_t$  = termino de error que tiene comportamiento de ruido blanco con varianza  $\sigma^2$

$\mu$  = *media*

$\phi$  = *pendiente*

Un alto valor de  $\phi$  indica una alta correlación y una negativa implica una alta oscilación en la serie de tiempo. Cuando la media es  $\mu$  y  $\phi = 1$  en la ecuación centrada en la media se llega a una caminata aleatoria o cuando en la ecuación inicial  $c=0$  y  $\phi = 1$  , a continuación, se mostrará en la ecuación centrada en la media.

$$Y_t - 0 = 0 + 1 * Y_t + u_t$$

$$Y_t = Y_{t-1} + u_t$$

Con los gráficos de Función de Autocorrelación (ACF en sus siglas en inglés) y la Función de Autocorrelación Parcial (PACF en sus siglas en inglés) se podrá identificar qué orden es, en este caso será un AR(1) el que se mostrará a continuación.




Gráfico 5: ACF y PACF del modelo AR

Se ven en el ACF que la autocorrelación con el pasado existe y se va “diluyendo” gradualmente, lo que indica que hay un comportamiento AR, y en el PACF se ve que 1 valor es significativo (los límites muestran a partir de qué valor es significativo. Entonces se puede concluir que es un modelo AR(1).

#### 1.4.7. Media Móvil (MA)

El MA es parecido al AR pero la autocorrelación es con los errores previos, no con los valores anteriores de la variable. La ecuación de un modelo simple con una autocorrelación de un periodo es la que se muestra a continuación.

$$Y_t = \mu + \varepsilon_t + \theta * \varepsilon_{t-1}$$

Términos:

$\varepsilon_t$  = termino de error que tiene comportamiento de ruido blanco con varianza  $\sigma^2$

$\mu$  = media

$\theta$  = pendiente

Si  $\theta = 0$  entonces se convierte en un ruido blanco con media  $\mu$  y varianza  $\sigma^2$ . Altos valores de la pendiente generarán una alta autocorrelación y un valor negativo generará una serie de tiempo oscilatoria.

Acerca de cómo es su comportamiento en los gráficos ACF y PACF. En los gráficos ACF mostrará qué tipo de modelo viendo los valores que sí son significativos.




Gráfico 6: ACF de un modelo MA




Gráfico 7: PACF de un modelo MA

En el ACF se ve que sale para arriba un valor significativo, lo cual hace imaginar que es un MA(1), sin embargo salen otros 2 más, así que podría ser también un MA(3); además se ve que en el PACF va reduciéndose poco a poco entonces eso indica también que indica a un modelo MA puro. En este caso es un MA (1).

### 1.4.8. ARMA

El modelo ARMA como se puede deducir por su nombre indica que es un modelo que tiene ambas cualidades, las AR y MA. Se puede ver en el gráfico ACF y PACF si tiene cierta tendencia. En ambos gráficos se verá la reducción gradual de ambos valores.




Gráfico 8: ACF y PACF del modelo ARMA

### 1.4.9. ARIMA

Hasta este punto de series de tiempo, se ha asumido que no ha habido un comportamiento con que la media no sea constante o la varianza vaya aumentando gradualmente. A continuación, se puede ver que en la primera imagen la media no es constante y la varianza va aumentando. Hay dos tratamientos para estos casos y volverlo estacionario como en la última imagen. Para una varianza no constante se aplica el logaritmo a la variable y para una media no constante se hace una diferencia con el periodo anterior.




Gráfico 9: Tratamiento de Datos

Fuente: Stoffer, D. (2020)

No es necesario que se apliquen siempre los dos tratamientos, sino cuando se requiera. La “1” de ARIMA se refiere a la cantidad de diferencias que se realizan hasta llegar a la estacionariedad. En lo demás es igual el ARMA, se podría decir que el ARIMA es un caso generalizado de AR, MA y ARMA. Existe un modelo más que se llama SARIMA, que la “S” indica que tiene un comportamiento estacional en ciertos puntos. No es el alcance del documento explicarlo, pero es bueno tener claro el panorama que abarca.

## **CAPÍTULO 2: CASOS DE ESTUDIO**

### **2.1. *Agri-food 4.0*: Una encuesta de las cadenas de suministros y futuras tecnologías en la agricultura**

Es un *paper*, el cual tiene el título en inglés originalmente, realizado por Mario Lezoche, Jorge E. Hernandez, Maria del Mar Eva Alemany Diaz, Hervé Panetto y Janusz Kacprzyk aceptado el 10 de enero del 2020. La investigación se enfoca en impulsar la agricultura, en términos usados por el texto, Agri-Food 4.0.

El término “Agri-Food 4.0” es un símil al término de “Industria 4.0”, viene del concepto “Agricultura 4.0”. Al igual que en la Industria 4.0, en donde se busca integrar e incluir las nuevas tecnologías para poder tener información a tiempo real para entender el comportamiento y rendimiento, se planea utilizar los drones y sensores para poder recolectar información que permita factores claves para la agricultura como el clima, ubicación geográfica, el comportamiento de los animales y de los cultivos hasta el ciclo de vida de la granja.

Al tener todos estos datos, se puede trabajar para llegar a información por medio de análisis o de predicciones que ayuden a tomar mejores decisiones en favor del rendimiento. Por otro lado, a través de la revisión de más de 100 *papers* se busca en este documento mostrar futuros caminos hacia el dominio de *Agri-Food* el cual aún es nuevo.

#### **2.1.1. Nuevas herramientas utilizadas en *Agri-Food 4.0***

No es nuevo todo sobre este tema, hace ya décadas se han utilizado innovaciones digitales especialmente en *Precision Agriculture*, sensores remotos, robots, sistema de manejo de información de granjas y decisiones soportados por sistemas. Lo reciente es la unión con la nube, Internet en las cosas, *Big Data*, *Blockchain*, robótica e inteligencia artificial.

Con el avance de lo último mencionado, podrá la agricultura evolucionar a un orientado a datos, inteligente, autónomo y ágil sistema conectado con otros sistemas.

Las herramientas que se buscan utilizar son las de Big Data, se busca integrar por ejemplo con la información que otorgan los satélites de Google y de la NASA la cual es información metro-lógica; los datos del suelo, agua y geoespaciales del Servicio de Conservación de Recursos Nacionales (EE.UU).

Acerca del Internet en las cosas, por medio de sensores se busca tener datos del agua, suelo, humanos, animales, etc. Con esto se tiene un ingreso de datos constantes. *Big Data*



en este caso, se enfoca en el manejo de la información e IoT se enfoca en la recolección de datos.

Luego de recolectar y manejar de manera correcta los datos, se busca llegar a tener información por medio de creación de modelos; sin embargo, se requiere definir cuáles serán los parámetros de decisión, en este caso podrían ser la ubicación, terreno, clima, plantas, tiempo, proceso, entre otros. Con la ayuda de la inteligencia artificial se llegaría a importantes contribuciones en creación de modelos para llegar al conocimiento.

La razón de su implementación según la lectura es que se reduce el costo en la reducción de decisiones erradas; además, se una simulación mucho más acertada y un camino más claro para seguir.

### **2.1.2. Cómo las nuevas tecnologías transforman la cadena de suministro de la agricultura**

La diferencia con las cadenas de suministros usuales en empresas es que tiene más fuentes de incertidumbre y riesgos, se mencionan cuatro en el *paper*: producto (tiempo de duración que puede ser guardada, grado de deterioro, falta de homogeneidad y seguridad alimenticia), proceso (producción, recursos necesarios, plazo de entrega de suministros y rendimiento del campo), mercado (demanda y precios del mercado) y medio ambiente (clima, pestes, desastres y regulaciones).

Una mala administración puede conllevar a un impacto negativo en seguridad, calidad, cantidad y pérdida de productos. Debido a eso, es importante las nuevas tecnologías, ya que reducen en gran manera la incertidumbre.

El texto explica los impactos en diversos campos y retos que puede tener la implementación de *IoT*, *Blockchain*, *Big Data Analytics* y *Artificial Intelligence*. En este caso, debido al tema del estudio, se mostrarán los gráficos solamente de *Big Data Analytics* y *Artificial Intelligence*

A continuación, se muestra lo redactado acerca de los impactos de *Big Data Analytics* según el documento.

Tabla 1: Impactos de Big Data Analytics

<i>Big Data Analytics</i>	
<b>Referencias</b>	<b>(Bronson and Knezevic,2016);(Ribarics,2016);(Wolfert et al.,2017);(Kamilaris et al.,2017);(Himesh,2018);(Saggi and Jain,2018);(Nguyen et al.,2018);(Rabah et al.,2018);(Kamble et al.,2020)</b>
<b>Impactos</b>	<b>Impacto funcional</b>
	<ul style="list-style-type: none"> <li>• La analítica descriptiva permite entender qué ha pasado y, por lo tanto, diagnóstico (identifica patrones, agrupaciones, identificar riesgo <i>agri-food</i>, benchmarking).</li> <li>• El análisis predictivo permite obtener información sobre lo que sucederá o es probable que suceda mediante la exploración de patrones en los datos (pronóstico de demanda, rendimiento, precio, clima, comportamiento del consumidor).</li> <li>• La analítica prescriptiva permite tomar mejores decisiones e influir en lo que debería estar sucediendo mediante la optimización matemática, simulación o técnicas de toma de decisiones multicriterio (toma de decisiones en tiempo real, automatización del uso de la robótica en la plantación de cultivos y planificación de la cosecha, distribución, diseño de redes, gestión de riesgos, etc.).</li> </ul>
	<b>Impacto económico</b>
	<ul style="list-style-type: none"> <li>• Mejorar la eficiencia operativa en general mediante la automatización y mejores decisiones.</li> <li>• Mejores optimizaciones de semillas y ganado y nuevas metodologías que mejoran el rendimiento y la producción.</li> <li>• Entrega más rápida y barata de los bienes producidos para la distribución a centros y consumidores.</li> <li>• Decisiones y alertas a tiempo real basada en datos de los campos y equipos.</li> <li>• Datos de rendimiento empresarial y de producción integrados para mejorar la toma de decisiones.</li> <li>• Datos de desempeño racionalizados en múltiples geografías.</li> <li>• Nuevos productos asegurados.</li> </ul>
	<b>Impactos ambientales</b>
	<ul style="list-style-type: none"> <li>• Mejor uso de recursos (tierra, agua, pesticidas).</li> <li>• Minimización de <i>food print</i>.</li> </ul>
	<b>Impacto social</b>
	<ul style="list-style-type: none"> <li>• Mejor servicio al cliente.</li> <li>• Reducción de riesgo.</li> <li>• Transformación de la agricultura tradicional basada en habilidades en una agricultura digital e impulsada por el conocimiento.</li> </ul>
<b>Impacto de negocio</b>	
<ul style="list-style-type: none"> <li>• Grandes cambios en los roles y las relaciones de poder entre los diferentes actores de la red de partes interesadas de la agricultura de Big Data. (por ejemplo, entre agricultores y grandes corporaciones).</li> <li>• Desarrollo de cadenas de suministros más cortas y nuevos modelos operativos.</li> <li>• Mejor comprensión de las necesidades del cliente y orientación a mercados de mayor valor.</li> <li>• Facilitar el desarrollo de plataformas comerciales en línea o cooperativas virtuales en línea.</li> <li>• El análisis de datos puede desempeñar un papel importante en el desarrollo de nuevos productos asegurados.</li> <li>• En última instancia, las empresas utilizarán <i>Big Data</i> porque crean valor al resolver nuevos problemas, así como resolver problemas existentes más rápido o más barato o proporcionar una mejor y más rica comprensión de esos problemas.</li> </ul>	
<b>Impacto tecnológico</b>	
<ul style="list-style-type: none"> <li>• <b>Capacidad de lidiar con las 5 V's.</b></li> <li>• Volumen (magnitud de datos).</li> <li>• Variedad (datos de fuentes heterogéneas).</li> <li>• Velocidad (velocidad de generación y entrega de datos, que se puede procesar por lotes, en tiempo real, casi en tiempo real o simplificar).</li> <li>• Veracidad (calidad de los datos y nivel de confianza).</li> <li>• Valor (detección de valores subexplotados de <i>Big Data</i> para apoyar la toma de decisiones).</li> </ul>	

Fuente: Lezoche. M, Hernandez. J, Alemany. M , Panetto. H, Kacprzyk (2020)

Cabe resaltar son los impactos funcionales, permite realizar diagnósticos, predecir diversas variables relevantes de la agricultura y permite mejorar en la parte prescriptiva las decisiones e influenciando qué se debe hacer por medio de optimizaciones matemáticas. Además, se sus otros impactos económicos, ambientales, sociales, de negocio y tecnológicos de la empresa. A continuación, se muestran los retos que tiene *Big Data Analytics* en su implementación y desarrollo en la empresa.

Tabla 2: Retos de Big Data Analytics

<b>Big Data Analytics</b>	
<b>Referencias</b>	(Bronson and Knezevic,2016);(Ribarics,2016);(Wolfert et al.,2017);(Kamilaris et al.,2017);(Himesh,2018);(Saggi and Jain,2018);(Nguyen et al.,2018);(Rabah et al.,2018);(Kamble et al.,2020)
<b>Desafios</b>	<b>Desafios organizacionales:</b>
	<p>Descentralización de <i>Big Data</i>.</p> <ul style="list-style-type: none"> <li>• Control de <i>Big Data</i> cuando hay múltiples actores involucrados.</li> <li>• Confianza, privacidad y seguridad de <i>Big Data</i> entre actores.</li> <li>• Monetización de <i>Big Data</i> (transferencia de derechos sobre los datos)</li> </ul>
	<b>Desafios sociales:</b>
	<ul style="list-style-type: none"> <li>• Demostrar el valor de las innovaciones en comparación con sus costos, para alentar a las empresas y las personas a recopilar e intercambiar datos.</li> <li>• Explorar las implicaciones éticos de <i>Big Data</i> den la alimentación y la agricultura</li> <li>• Disponibilidad de recursos humanos capacitados para el análisis de <i>Big Data</i>.</li> </ul>
<b>Desafios tecnológicos:</b>	<p><b>Mejorando la capacidad de lidiar con las 5V's</b></p> <ul style="list-style-type: none"> <li>• Volumen (los datos aumentaron exponencialmente, lo que representa un desafío para la capacidad de los dispositivos de almacenamiento).</li> <li>• Variedad (integración sostenible y combinación de datos de diferentes fuentes: sensores, Internet de las cosas (IoT), dispositivos móviles, redes sociales, en formatos estructurados, semiestructurados y no estructurados).</li> <li>• Velocidad (procesamiento de datos en tiempo real).</li> <li>• Veracidad (garantizar calidad y fiabilidad)</li> <li>• Valor (proporcione más valor y conocimientos a partir de los datos).</li> <li>• Valence (soporte de conectividad en datos). El potencial de conectividad entre sistemas se ve limitado por la falta de datos comunes estándares u ontologías fáciles de usar.</li> <li>• Combinar los tres niveles de analítica: el rendimiento de la analítica prescriptiva dependería en gran medida de los de analítica descriptiva y análisis predictivo desde que proporciona el valor de los parámetros de entrada en el modelo prescriptivo.</li> <li>• Combinando diferentes técnicas de análisis de datos para desarrollar modelos BDA más avanzados y adaptables para DSS.</li> <li>• Falta de herramientas de apoyo a la toma de decisiones y voluntad de compartir datos.</li> <li>• Nuevas herramientas y técnicas BDA para SC distribuido y computación distribuida Integración con otras tecnologías.</li> </ul> <p>• Apertura de plataformas para acelerar el desarrollo de soluciones y la innovación en general, pero también para empoderar a los agricultores en su posición en cadenas de suministro.</p>

Fuente: Lezoche. M, Hernandez. J, Alemany. M , Panetto. H, Kacprzyk (2020)

Por otro lado, también se mostrarán los impactos y retos que tiene la inteligencia artificial en una empresa enfocada a la agricultura.

Tabla 3: Impactos de la Inteligencia artificial

Inteligencia Artificial	
Referencias	(Mercy et al.,2011);(Liakos et al.,2018);(Divya and Sreekumar,2014);(Mishra et al.,2014);(Mishra et al.,2016);(Elsayed et al.,2018);(Reshma and Pillai,2018)
Impactos	<b>Impactos funcionales</b> <b>Técnicas que permite el AI</b> <ul style="list-style-type: none"> <li>• Clasificación: para predecir las categorías de datos de entrada, por ejemplo, los atributos meteorológicos son soleado, ventoso, lluvioso, etc.</li> <li>• Regresión: para predecir el valor numérico, por ejemplo, el precio de las acciones.</li> <li>• Agrupación: para organizar elementos similares en grupos.</li> <li>• Análisis de asociación: para encontrar relaciones interesantes entre conjuntos de variables.</li> <li>• Análisis de gráficos: utilizar la estructura gráfica para encontrar conexiones entre entidades.</li> <li>• Árboles de decisión: para predecir los conocimientos de modelado de variables objetivas mediante el aprendizaje de reglas de decisión simples inferidas de las características de los datos.</li> </ul> <b>Las capacidades anteriores se han aplicado a:</b> <ul style="list-style-type: none"> <li>• Manejo de cultivos (predicción de rendimiento, detección de enfermedades, detección de malezas, plagas de insectos, estrés biótico en el cultivo, calidad del cultivo, reconocimiento de especies, predicción de la humedad del suelo).</li> <li>• Gestión del agua (sistemas de riego inteligentes).</li> <li>• Predicción del tiempo.</li> <li>• Manejo del suelo.</li> <li>• Monitoreo más rápido y con mayor precisión que otros sistemas de monitoreo.</li> <li>• Clasificación y agrupamientos.</li> <li>• Sistema de detección de fraudes a muy alta velocidad, eficiencia y a gran escala.</li> <li>• Ganadería (bienestar animal, producción ganadera).</li> <li>• Protección del medio ambiente.</li> <li>• Planeación de producción.</li> </ul>
	<b>Impacto económico</b> <ul style="list-style-type: none"> <li>• Reducción de costos en capacitación de empleados</li> <li>• Genera eficiencias, mejora soluciones de problemas y reduce el tiempo necesario para resolverlos.</li> </ul>
	<b>Impactos sociales</b> <ul style="list-style-type: none"> <li>• Combina múltiples inteligencias humanas expertas.</li> <li>• Reduce la cantidad de errores humanos.</li> <li>• Revise las transacciones que los expertos humanos pueden pasar por alto.</li> <li>• Reducir la intervención humana permitiendo que los expertos humanos se concentren en actividades más creativas.</li> </ul>
	<b>Impactos de negocio</b> <ul style="list-style-type: none"> <li>• Toma de decisiones automatizadas</li> <li>• El sistema experto aumenta la probabilidad, frecuencia y consistencia de tomar buenas decisiones, efecto aditivo del conocimiento de muchos expertos en el dominio, facilita las decisiones de nivel experto en tiempo real y de bajo costo por parte de los no expertos, mejora la utilización de la mayoría de los datos.</li> <li>• Capacidad de aprendizaje de la Inteligencia Artificial, va un paso más allá al no simplemente aplicar decisiones preprogramadas, sino exhibir algunas capacidades de aprendizaje.</li> <li>• Transformación de datos: ML e IA pueden ayudar a crear valor al proporcionar a las empresas un análisis inteligente de big data y la captura de interpretaciones estructuradas de la amplia variedad de datos no estructurados cada vez más disponibles.</li> </ul>
	<b>Impactos tecnológicos</b> <ul style="list-style-type: none"> <li>• El avance del aprendizaje automático con visión artificial hará que las tecnologías agrícolas sean precisas, robustas y de bajo costo.</li> <li>• La IA se puede utilizar para identificar y limpiar datos sucios o utilizar datos sucios como un medio para establecer el conocimiento del contexto de los datos.</li> <li>• La IA contribuye a la velocidad de los datos al facilitar decisiones rápidas basadas en computadora que conducen a otras decisiones.</li> <li>• La IA contribuye a la mitigación de la variedad al capturar, estructurar y comprender datos no estructurados que generan datos de estructura.</li> <li>• La IA permite el análisis de datos y la toma de decisiones.</li> <li>• Desde máquinas inteligentes hasta computadoras inteligentes y programas de inteligencia artificial (IA).</li> <li>• Sistemas expertos desarrollados en idiomas regionales para ser más accesibles.</li> </ul>

Fuente: Lezoche. M, Hernandez. J, Alemany. M , Panetto. H, Kacprzyk (2020)

Opto por resaltar los impactos funcionales, permite realizar clasificaciones, regresiones, agrupaciones, análisis de asociación, análisis de gráficos, árboles de decisiones, entre otros. Como se ha mencionado, la inteligencia artificial tiene un enfoque más funcional, lo

cual permite tener un gran alcance en resolución de problemas. Al igual que en Big Data tiene impactos sociales, de negocio, tecnológicos y económicos.

A continuación, se muestra los retos que afronta la inteligencia artificial.

Tabla 4: Retos de la Inteligencia Artificial

Inteligencia Artificial	
Desafíos	<b>Desafíos sociales:</b>
	<ul style="list-style-type: none"> <li>• Reemplazo de la intervención humana percibida como una amenaza.</li> </ul>
	<b>Desafíos tecnológicos:</b>
	<ul style="list-style-type: none"> <li>• IA para facilitar aún más desarrollos adicionales en la visualización.</li> <li>• Los algoritmos de IA diseñados para entornos de una sola máquina pueden tener estructuras de subproblemas emergentes útiles para la paralelización.</li> <li>• Se puede demostrar que agregar una interfaz de voz al sistema es más beneficioso para los agricultores del área remota.</li> <li>• Los sistemas expertos no podrán dar las respuestas creativas que los expertos humanos pueden dar en circunstancias inusuales.</li> <li>• Falta de flexibilidad y capacidad para adaptarse a entornos cambiantes.</li> <li>• No poder reconocer cuando no hay respuesta disponible.</li> <li>• La adquisición de conocimientos sigue siendo el principal obstáculo en la aplicación de tecnología de sistemas expertos a nuevos dominios.</li> <li>• El mantenimiento y la extensión de una base de reglas puede ser difícil para una base de reglas relativamente grande.</li> <li>• Mejore el IoT con técnicas de aprendizaje automático para analizar los datos capturados por sensores en tiempo real en la agricultura.</li> </ul>

Fuente: Lezoche. M, Hernandez. J, Alemany. M , Panetto. H, Kacprzyk (2020)

Como se puede contrastar, tiene menos retos, eso que es más fácil aplicarlo en una empresa, los retos son más que nada tecnológicos. Pero hay retos como empresa y uno social solamente.

## 2.2. La integración basada en el aprendizaje automático de los factores de sequía detectados de forma remota puede mejorar la estimación de la sequía agrícola en el sureste de Australia

La investigación fue realizada por Puyu Feng, Bin Wang, De Li Liu y Qiang Yu en el 2019, en este estudio se busca realizar predicciones de sequías para el sureste de Australia a partir de 30 factores obtenidos de los sensores de los satélites del TRMM (*Tropical Rainfall Measuring Mission*) y MODIS (*Moderate Resolution imaging spectroradiometer*) para un mejor rendimiento de los campos de trigo. Lo busca realizar a través de diversas herramientas de aprendizaje automático como máquinas de soporte de vectores, redes neuronales con varias capas de perceptrones y bosques aleatorios con corrección de sesgo orientados a modelos de regresión. Acerca de las métricas que se usarán para determinar cuál es el mejor modelo en este caso serán el RMSE (*root mean square error*) y el valor más alto de  $R^2$ .

Por otro lado, acerca de las sequías se encuentran cuatro tipos comunes: sequías meteorológicas, sequías agrícolas, sequías hidrológicas y sequías socioeconómicas. Los tipos de sequías mencionadas previamente se interrelacionan. La sequía agrícola es la más importante como problema más serio en muchos países en términos de economía, estabilidad social y seguridad alimentaria. Es cuando el agua del suelo es baja por las precipitaciones por debajo de lo normal y el exceso de evaporación y transpiración.

### 2.2.1. Alcance del estudio

El área elegida ocupada unos 360.000 km<sup>2</sup>, es aproximadamente un 28% del área total de trigo en Australia. En esta gran área varía aspectos climatológicos y topográficos, debido a eso se realizó una distinción entre las áreas de cultivo de secano y otros tipos. En la siguiente imagen los de color verde son los cultivos de secano. Agricultura de secano de secano se refiere en donde no entra la mano del hombre para realizar la agricultura, sino que proviene de las lluvias la irrigación. A continuación, se muestra el mapa que fue elaborado por *Geoscience Australia* y fue mostrado en el *paper*.

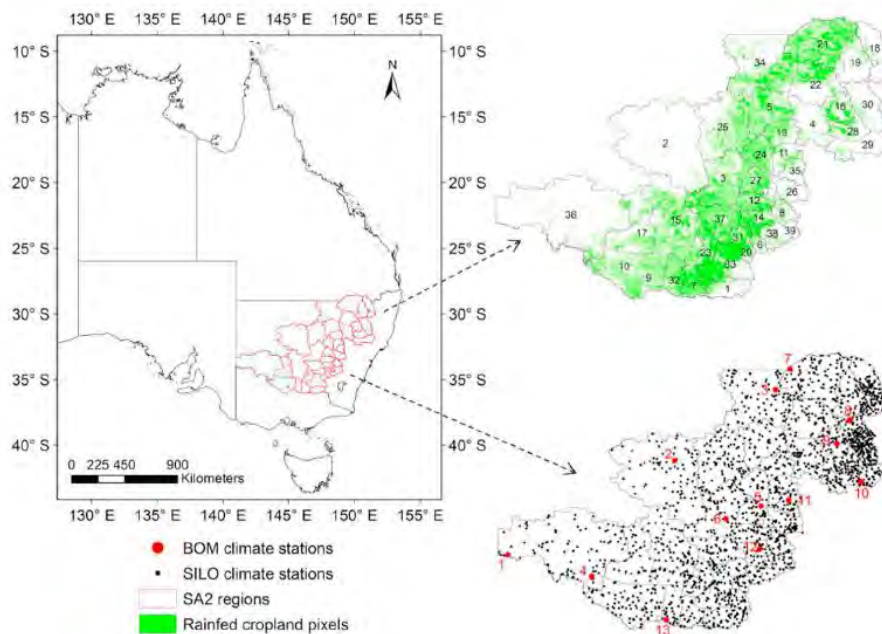


Figura 17: Mapa de áreas de cultivo de secano

Fuente: Feng.P , Wang.B, Liu.D,Yu.Q (2019)

Los puntos rojos que se muestran son una *Bureau of Meteorology* (BOM) y *Scientific Information for Land Owners* (SILO). Son estaciones que realizan mediciones que también serán utilizadas.

### 2.2.2. Datos

Primero se estandarizó los datos numéricos para que no se afecte el análisis por temas de unidades métricas. Los índices utilizados para la predicción son a partir de los 30 mencionados al inicio y son las siguientes que se muestra en la figura 29.

Tabla 5: Índices para la predicción de sequías agrícolas en el New South Wales

Indexes	Definition	Formula	Resolution	Source
Pre	Precipitation	-	0.25*	TRMM/3D43
PET	Potential evapotranspiration	-	500 m	MODIS
ET	Evapotranspiration	-	500 m	MODIS
LSTd	Land surface temperature-day	-	1 km	MODIS
LSTn	Land surface temperature-night	-	1 km	MODIS
LSTm	Land surface temperature-mean	$(LSTd+LSTn)/2$	1 km	MODIS
NDVI	Normalized difference vegetation index	$(b2-b1)/(b2+b1)$	500 m	Rouse Jr et al.(1974)
EVI	Enhanced vegetation index	$2.5*((b2-b1)/(b2+6*b1-7.5b3+1))$	501 m	Huete et al.(2002)
NMDI	Normalized multi-band drought index	$(b2-(b6-b7))/b2+(b6-b7))$	502 m	Wang and Qu (2007)
NDMWI5	Normalized difference wated index	$(b2-b5)/(b2+b5)$	503 m	Gao(1996)
NDMWI6	Normalized difference vegetation index	$(b2-b6)/(b2+b6)$	504 m	Gao(1996)
NDMWI7	Normalized difference vegetation index	$(b2-b7)/(b2+b7)$	505 m	Gao(1996)
NDDI5	Normalized difference drought index	$(NDVI-NDWI5)/(NDVI+NDWI5)$	506 m	Gu et al. (2007)
NDDI6	Normalized difference drought index	$(NDVI-NDWI6)/(NDVI+NDWI6)$	507 m	Gu et al. (2007)
NDDI7	Normalized difference drought index	$(NDVI-NDWI7)/(NDVI+NDWI7)$	508 m	Gu et al. (2007)

Fuente: Feng.P , Wang.B, Liu.D,Yu.Q (2019)

Por otro lado, está la información de BOM donde tiene latitud, longitud, elevación, precipitación promedio anual (AP) y temperatura promedio anual (AT). Acerca de los datos de SILO, se tomaron de 2242 estaciones climatológicas y se usarán para contrastar las predicciones del modelo.

Tabla 6: Datos de BOM

ID	Latitude	Longitude	Elevation (m)	AP (mm)	AT (°C)
1	-34.0	141.3	26.0	258.0	17.7
2	-31.5	145.8	260.0	389.0	19.4
3	-29.5	148.6	145.0	532.0	20.3
4	-34.6	143.6	61.0	336.0	17.3
5	-32.7	148.2	285.0	589.0	18.4
6	-33.1	147.2	198.0	460.0	17.7
7	-29.0	149.0	160.0	502.0	20.8
8	-30.4	150.6	500.0	699.0	16.6
9	-31.0	150.3	307.0	640.0	18.8
10	-32.1	150.9	216.0	623.0	17.7
11	-32.6	149.0	305.0	644.0	17.1
12	-33.9	148.2	190.0	630.0	16.3
13	-35.8	145.6	114.0	459.0	16.2

Fuente: Feng.P , Wang.B, Liu.D,Yu.Q (2019)

La medida que se utiliza para ver cómo están las condiciones del suelo es su rendimiento; en este caso, se consiguieron de *Yield Gap Australia* que tiene su propia página. En la figura 31 se mostrarán los valores por región a partir de una recolección de información del 2001 al 2014, AP y AT significan lo mismo que en la anterior tabla.

Tabla 7: Descripción de las áreas de nivel 2 (SA2) regiones de New South Wales

ID	Region	Latitude	Longitude	AP (mm)	AT (°C)	Yield (t ha <sup>-1</sup> (-1))
1	Albury Region	-36	146.9	697	15.2	2.31
2	Cobar	-31.5	145.8	394	18.8	1.15
3	Condobolin	-33.1	147.1	441	17.5	1.33
4	Coonabarabran	-31.3	149.3	783	15.8	1.86
5	Coonamble	-31	148.6	543	18.8	1.41
6	Cootamundra	-34.6	148	642	15.3	2.67
7	Corowa Region	-36	146.4	558	15.1	2.09
8	Cowea Region	-33.8	148.7	618	15.9	2.17
9	Deniliquin	-35.5	145	398	16.3	1.78
10	Deniliquin Region	-35.3	144.3	369	16.5	1.77
11	Dubbo Region	-32.3	148.6	609	17.3	1.8
12	Forbes	-33.7	148	535	16.7	1.63
13	Gilgandra	-31.7	148.7	580	19.1	1.51
14	Grenfell	-33.9	148.1	616	16.2	1.89
15	Griffith Region	-34.3	146	427	17	1.87
16	Gunnedah Region	-31	150.3	645	18.5	2.45
17	Hay	-34.7	144.8	355	17	1.88
18	Inverell Region-East	-29.6	151.2	776	16	1.94
19	Inverell Region-West	-29.9	150.6	746	18	2.52
20	Junee	-34.9	147.6	544	15.6	2.47
21	Moree Region	-29.5	149.8	600	19.3	1.98
22	Narrabri Region	-30.3	149.8	637	18.7	2.14
23	Narrandera	-34.7	146.6	431	16.5	1.91
24	Narromine	-32.3	148.2	609	17.3	1.73
25	Nyangan-Warren	-31.6	147.5	475	18.8	1.37
26	Orange Region	-33.3	149.1	649	16.5	2.01
27	Parkes Region	-33.1	148.2	576	17.2	1.56
28	Quirindi	-31.5	150.7	662	17.3	2.88
29	Scone Region	-32.1	150.9	662	17.3	2.33
30	Tamworth Region	-31.1	150.9	681	17.2	2.17
31	Temora	-34.5	147.5	514	15.5	2.11
32	Tocumwa-Finley-Jerilderie	-35.6	145.6	430	16.2	2.27
33	Wagga Wagga Region	-35.1	147.4	575	15.7	2.15
34	Walgett- Lightning Ridge	-29.7	148	468	20.2	1.19
35	Wellington	-32.6	148.9	629	16.5	1.97
36	Wentworth-Balranald Region	-34.1	142.6	287	17.3	1.6
37	West Wyalong	-33.9	147.2	483	16.9	1.66
38	Young	-34.4	148.3	696	14.4	2.4
39	Young Region	-34.4	148.7	715	13.7	2.38

Fuente: Feng.P , Wang.B, Liu.D,Yu.Q (2019)

### 2.2.3. Metodología

A partir del algoritmo de agrupación k-medios se llegó a dos agrupaciones donde agrupa el clima de BOM. Luego se analizó el AP y AT de cada grupo, colocando las respectivas estaciones que corresponden a cada agrupación. A continuación, se muestra la tabla que se realizó.

Tabla 8: Clústeres formados con sus características

Clusters based on K-means algorithm	BOM station's ID	AP (mm)	AT (°C)
Cluster 1	1,2,3,4,6,7,13	419	18.5
Cluster 2	5,8,9,10,11,12	638	17.5

Fuente: Feng.P , Wang.B, Liu.D,Yu.Q (2019)



En la siguiente figura se muestra la tabla de correlaciones de las 30 variables.




Figura 18 : Correlación de las variables

Fuente: Feng.P , Wang.B, Liu.D,Yu.Q (2019)

Se adiciona a la tabla el SPEI, que es el índice de evapotranspiración de precipitación estandarizado que fue creado por Vicente-Serrano (2010). Es especialmente utilizado para análisis de sequías. El valor de menos a -1 indica condiciones de sequía. Las otras variables han sido explicadas previamente. Como se visualiza, se han sido separadas en 1 y 3, el 1 es del primer mes y el 3 indica el tercer mes en la escala media de tiempo.

La gráfica no está en forma de “espejo”, esto se debe a que la parte de arriba corresponde al grupo 2 y el de abajo al grupo 1, al ver las correlaciones se podrá determinar cuáles variables son importantes para cada grupo y así seleccionar las más adecuadas y retirando las redundantes.

### 2.2.4. Resultados

Luego de realizar las evaluaciones con cada una de las herramientas de aprendizaje automático o *machine learning*, como se le conoce más comúnmente. Se utilizaron las medidas para evaluar el desempeño de cada modelo. Se muestra a continuación las fórmulas.

$$R^2 = \left( \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}}$$

Se realizaron 100 corridas y a partir de los valores que salieron, se creó este gráfico.

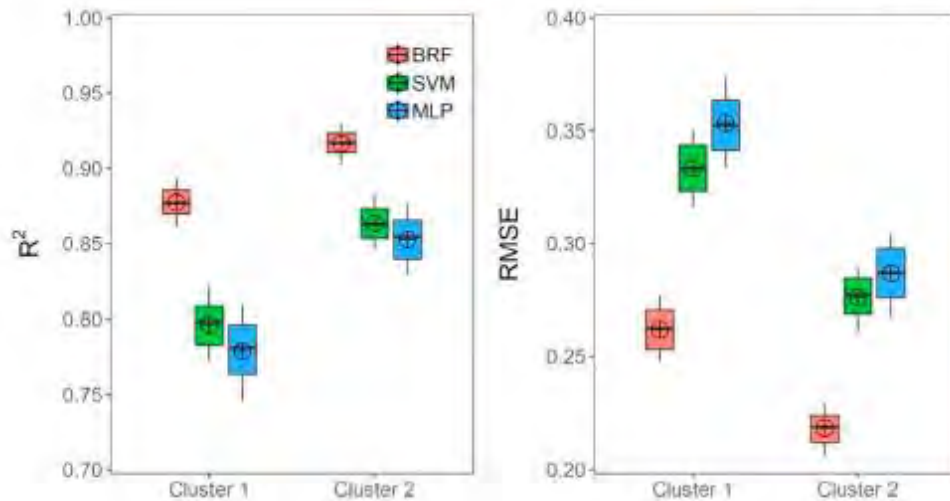


Figura 19 : Evaluación precisión y error de los modelos

Fuente: Feng.P , Wang.B, Liu.D,Yu.Q (2019)

Como se puede ver, el BRF logró un mayor R<sup>2</sup> y menor RMSE en ambos *clusters*. Por otro lado, el *cluster 2* muestra que los modelos lo explicaron mejor que lo que explicaron al *cluster 1*. Entonces se eligió al BRF para realizar las predicciones y contrastarlas con la información de SILO.

Se contrastó con 3 años un año normal (2001), uno seco (2002) y uno húmedo (2010). El modelo identificó satisfactoriamente los periodos de sequías y las zonas afectadas por ellas. Con respecto a la correlación espacial y la función de distribución acumulada (CDF por sus siglas en ingles); la correlación espacial tuvo una correlación de 0.45 a 0.92 con un nivel medio de 0.71, lo que implica una alta correlación y acerca del CDF tuvo un buen desempeño ya que según las gráficas realizadas a tenido una casi superposición sobre los datos reales.

## **CAPÍTULO 3: ANÁLISIS DEL PERÚ**

El Perú es un país que se encuentra en Sudamérica, tiene 24 departamentos y Lima es su capital. El español es el lenguaje que predomina con un 80.3% y 16.2% de quechua, 3% de otros idiomas y 0.2% de lenguas extranjeras. Su moneda es el Nuevo Sol (S/) desde 1991 y se divide en 100 céntimos.

Las regiones en las que se divide son tres: costa, andina y selva. La costa consta de desiertos, playas, ríos y valles fértiles; la región andina tiene áreas semidesérticas, nevadas y con valles altiplanos, lagos y ríos; la selva se presenta como selva alta y baja.

### **3.1. Actividades económicas**

El país tiene como principales actividades la minería y agropecuario, es un país exportador. La revista “La Cámara” de la Cámara de Comercio de Lima (CCL), habla de cómo el Perú es un país “minero y agropecuario” por su mayor dinamismo en el PBI. Viendo cómo se iba desarrollando del 2009 al 2018 se ve que la minería creció en promedio 3.7% y el sector agropecuario 3.7%; por otro lado, la pesca 1% y la manufactura primaria 0.8%.

El BBVA *Research* realizó el “Informe de Exportaciones Agrícolas” en el 2018 donde destaca la venta al exterior de las frutas, en especial uva, paltas y arándanos (representaron el 65% de estas exportaciones) y de legumbres (el espárrago conformaba un 50%). La suma de estos productos fue de USD 2.500 millones. El economista jefe de BBVA *Research*, Hugo Perea, menciona que se ha visto favorecido debido al mayor gasto mundial en alimentos por las economías. Además, coincidió las aperturas comerciales (tratados de libre comercio) y otros factores.

Además, menciona que existen elementos que podrían potenciar el desarrollo agrícola, los cuales serían los mercados que se encuentran en rápida expansión. China surge como una oportunidad importante e India y Turquía los cuales andan creciendo el valor de importaciones por encima del promedio del mercado.

## PERÚ | EXPORTACIONES AGRÍCOLAS\* (USD MILLONES)

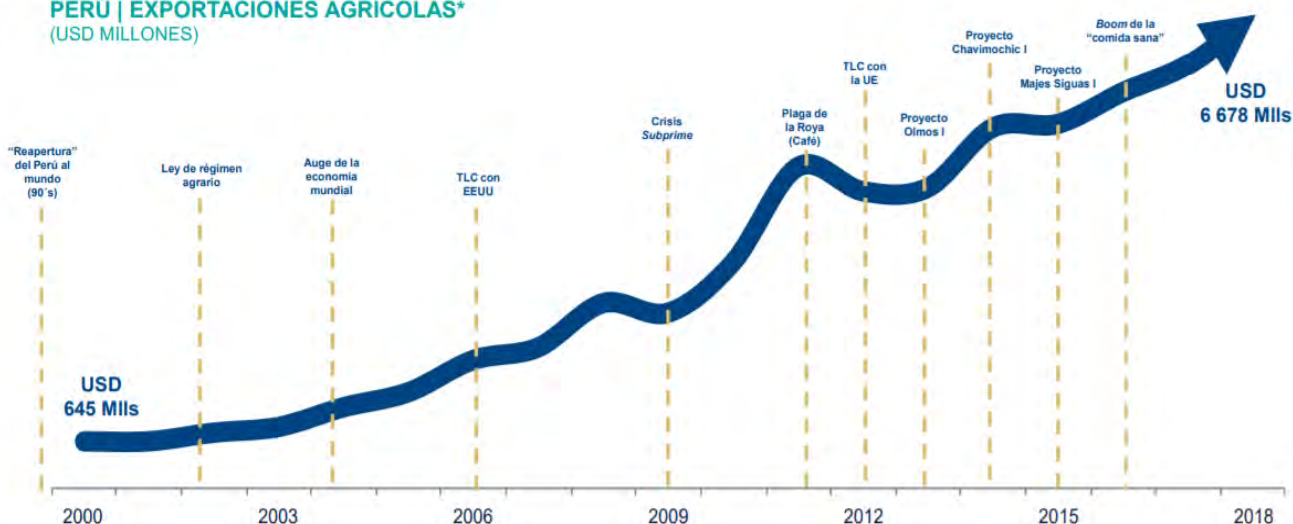


Figura 20: Evolución en USD millones en la exportación agrícola peruana

Fuente: BCRP, INEI, MINCETUR, ProInversión, SUNAT, BBVA Research (2019)

### 3.2. La palta

Para poder tener un panorama acerca de la palta, hay varios tipos en el Perú como la Criolla, dedo, Hass, Fuerte, Naval, Villa, Pinkerton, entre otras. Sin embargo, las que abarca mayor mercado en el Perú es la Fuerte y las que se exportan son la Hass, Fuerte y Pinkerton, la Hass tiene más fuerza en el mercado extranjero. Según la página Red agrícola en septiembre del 2019, publica "Palta éxitos y excesos" donde menciona lo siguiente: "A pesar de que el consumidor local prefiere consumir la variedad Fuerte, el 95% de las exportaciones de palta son de la variedad Hass. La preferencia por ella en el exterior se debe a la dureza de su cáscara, que cumple con las condiciones perfectas para la exportación. El 90% de la producción nacional de esta variedad se destina a los mercados foráneos, mientras que el 10% se dirige al consumo nacional."

Por otro lado, es muy demandada como fruta en el extranjero, más allá que sea más fácil su exportación por su cáscara, tiene una ventaja nutricional contrastada con otras paltas, además de que tiene un sabor más agradable. Se muestra a continuación su contenido nutricional, otorgado por la Comisión de Promoción del Perú para la Exportación y el turismo (PromPerú).

Tabla 9: Composición de la palta Hass

Valor nutricional (Por 100g)	
Componentes	Por 100g
Energía	131 kcal
Agua	79.2 g
Proteína	1.7 g
Grasa Total	12.5 g
Carbohidratos	5.6 g
Fibra dietaria	6.7 g
Calcio	37 mg
Zinc	0.61 mg
Hierro	0.6 mg
Retinol	7 µg
Vitamina A	7 µg
Tiamina	0.09 mg
Revolavina	0.05 g
Niacina	0.82 mg
Vitamina C	8 mg

Fuente: PromPerú (2020)

Al saber todas estas cualidades y el tema contextual de cómo se desenvuelve esta fruta como camino para crecer en la exportación, se tomará a la palta Hass para desarrollarla. Como se verá más adelante, Perú no importa palta, lo que produce básicamente es para consumo interno, y la Hass con otros tipos se exportan, siendo la Hass la representativa.

### 3.3. Exportaciones e importaciones de Perú con la palta

Como se ha explicado previamente, el Perú tiene como característica que es un país exportador. Como este estudio va orientado a la palta por su gran capacidad de otorgar trabajo según el Diario Oficial El Peruano que menciona que 1 de cada 4 empleos formales es por la agricultura y, además, de la aceleración en crecimiento de exportaciones que tiene el tipo Hass, más adelante se podrá visualizar mejor cómo se ha ido desarrollando a través de los años. Las entidades que se ven involucradas con el tema de exportaciones e importaciones son el Ministerio de Agricultura y Riego (MINAGRI), Ministerio de Comercio Exterior y Turismo (MINCETUR), Superintendencia Nacional de Aduanas y de Administración Tributaria (SUNAT), Ministerio de Transportes y Comunicaciones (MTC), Asociación de Exportadores (ADEX), entre otros.

#### 3.3.1. Importación de la palta

Acerca de la importación, primero es importante mostrar que el Perú históricamente hablando, no es un país importador de la palta. La Dirección de Gestión de Innovación Agraria (DGIA), en el 2008 publicó un histórico de importaciones realizadas por el Perú en el informe “Estudio de palta en el Perú y el Mundo”, que abarca del 1998 al 2007 y solo

hay importaciones en 1998,2006 y 2007, donde explica que en el 2007 fue para el abastecimiento de supermercados.

Tabla 8: Actividades de la palta en el comercio exterior

Año	Aprovisionamiento				Utilización				
	Producción (t)	Importación (t)	Exportación (t)	Demanda interna aparente (t)	Mermas(t)	Disponibilidad (t)	Desperdicios (t)	Disponibilidad (t)	Per-capita (kg/año)
1998	67222	34	2	67254	6725	60528	21185	39343	2
1999	78037	0	480	77558	7756	69802	24431	45371	2
2000	83671	0	2209	81462	8146	73316	25660	47655	2
2001	93459	0	2500	90959	9096	81863	28652	53511	2
2002	94239	0	4829	89407	8941	80466	28163	52303	2
2003	99975	0	11520	88456	8846	79610	27863	51746	2
2004	108460	0	14598	93862	9386	84476	29566	54909	2
2005	103417	0	18670	84747	8475	76272	26695	49577	2
2006	113278	22	31718	81582	8158	73424	25698	47725	2
2007	121720	404	37525	84599	8460	76139	26649	49490	2

Fuente: DGIA (2008)

Por otro lado, en TradeMap se puede obtener los datos del 2001 al 2019. Juntando las fuentes, las cuales concuerdan con los valores, se diagramará un gráfico para que se pueda ver visualmente el comportamiento de las importaciones de Perú de la palta. El único proveedor ha sido Chile.

IMPORTACIONES POR AÑO EN TONELADAS




Gráfico 10: Importaciones por año en toneladas de Perú

Sierra y Selva Exportadora (SSE) junto con el MINAGRI publicaron un análisis de la palta del 2015 al 2019, se muestra los principales países que importan la palta, la siguiente tabla mostrará la lista y la cantidad en miles de toneladas.

Tabla 9: Evolución de las importaciones de palta por país

País	Volumen en miles TM					Nivel de participación					CAGR (2015-2019)	% VAR (2019/2018)
	2015	2016	2017	2018	2019	2015	2016	2017	2018	2019		
<b>Total Importación</b>	<b>1811</b>	<b>2022</b>	<b>2153</b>	<b>2613</b>	<b>2635</b>	<b>100.0%</b>	<b>91.5%</b>	<b>91.1%</b>	<b>90.6%</b>	<b>92.5%</b>	<b>7.8%</b>	<b>0.8%</b>
<b>EE.UU.</b>	867	860	900	1038	1105	47.9%	42.5%	41.8%	39.7%	42.0%	5.0%	6.5%
<b>Países Bajos</b>	187	247	267	345	349	10.3%	12.2%	12.4%	13.2%	13.2%	13.2%	1.0%
<b>Francia</b>	117	135	146	157	165	6.4%	6.7%	6.8%	6.0%	6.3%	7.2%	4.8%
<b>España</b>	61	88	99	129	136	3.4%	4.3%	4.6%	4.9%	5.2%	17.4%	5.2%
<b>Reino Unido</b>	77	100	105	118	116	4.3%	4.9%	4.9%	4.5%	44.0%	8.5%	-1.1%
<b>Canadá</b>	70	78	80	94	95	3.9%	3.9%	3.7%	3.6%	3.6%	6.3%	0.8%
<b>Alemania</b>	48	59	73	94	91	2.7%	2.9%	3.4%	3.6%	3.5%	13.5%	-2.5%
<b>Japón</b>	58	74	61	74	77	3.2%	3.7%	2.8%	2.8%	2.9%	6.1%	4.3%
<b>Chile</b>	19	25	10	57	46	1.0%	1.3%	50.0%	2.2%	1.8%	19.9%	-18.5%
<b>Rusia</b>	12	12	19	29	36	0.7%	0.3%	0.9%	1.1%	1.4%	24.7%	21.8%
<b>China</b>	16	25	32	44	33	0.9%	1.2%	1.5%	1.7%	1.2%	15.3%	-25.8%
<b>Bélgica</b>	20	29	29	28	32	1.1%	1.4%	1.3%	1.1%	1.2%	9.1%	12.4%
<b>Italia</b>	11	14	17	22	26	0.6%	0.7%	0.8%	0.8%	1.0%	18.3%	17.0%
<b>Polonia</b>	9	10	14	20	22	0.5%	0.5%	0.6%	0.8%	0.9%	20.2%	13.3%
<b>Suecia</b>	18	19	21	21	20	1.0%	0.9%	1.0%	0.8%	0.8%	2.3%	-5.8%
<b>Dinamarca</b>	14	14	15	22	20	0.8%	0.7%	0.8%	0.7%	0.7%	6.8%	-11.0%
<b>Argentina</b>	11	13	19	14	18	0.6%	0.6%	0.9%	0.5%	0.7%	10.8%	25.7%
<b>Hong Kong, China</b>	8	17	21	24	18	0.4%	0.8%	1.0%	0.9%	0.7%	17.9%	-27.0%
<b>Arabia Saudita</b>	17	18	20	19	17	0.9%	0.9%	1.0%	0.7%	0.7%	3.0%	-9.4%
<b>Suiza</b>	11	14	15	16	16	0.6%	0.7%	0.7%	0.6%	0.3%	7.2%	3.6%
<b>Australia</b>	15	20	16	14	15	0.8%	1.0%	0.8%	0.5%	0.3%	-2.0%	11.4%
<b>Noruega</b>	12	12	12	13	14	0.6%	0.6%	0.6%	0.5%	0.5%	3.6%	9.2%
<b>Otros países</b>	132	140	162	221	168	7.3%	6.9%	7.5%	8.4%	6.4%	4.8%	-24.1%

Fuente: Sierra Exportadora (2020)

Como se puede ver Perú no está por en la tabla y el valor que importó históricamente según el gráfico 8, no es significativo con el valor que exporta y produce, lo cual se verá a detalle en el siguiente punto.

### 3.3.2. Exportación de la palta

Acerca de la exportación de la palta, como se ha hablado previamente que es principalmente de la Hass, tiene un gran mercado en el exterior y está el Perú dentro de los países que más exportan en el mundo como segundo lugar, junto con México en primer lugar y Países Bajos como tercer lugar. Sin embargo, según el reporte del MINAGRI y SSE, somos los terceros en exportación en términos de millones de dólares americanos, primero está México y segundo está Países Bajos. Se analizará lo objetivo, que vendría a ser la cantidad en toneladas. La siguiente tabla muestra los países que más exportan con la cantidad que exportan según Food and Agriculture Organization of the United Nations (FAO).

Tabla 10 : Top 10 de países exportadores de palta en toneladas

Nº	País	2015	2016	2017	2018
1	México	863,503	926,596	896,557	1,091,937
2	Perú	175,640	194,098	247,363	360,656
3	Países Bajos	149,322	195,924	243,810	312,265
4	Chilne	90,010	147,124	177,236	132,525
5	Spaña	85,738	93,721	107,904	109,301
6	Sudáfrica	48,798	57,866	43,492	89,343
7	Kenya	43,099	47,998	51,507	71,877
8	Estados Unidos	37,866	53,337	50,907	68,477
9	Israel	37,658	25,324	33,419	33,193
10	República Dominicana	14,661	23,714	31,000	33,775

Fuente: FAO (2019)

Acerca de cómo ha sido la evolución de las exportaciones peruanas sobre la palta, ha sido exponencial. Como se muestra en el gráfico 10.

#### TONELADAS DE PALTA EXPORTADAS - PERU




Gráfico 11: Toneladas de palta exportadas por el Perú del 2000 al 2018

Esto se debe también al crecimiento de demanda por parte de sus principales importadores. Como Países Bajos, Estados Unidos, España, Reino unido, entre otros. Del mismo estudio del MINAGRI y SSE se extrae una tabla donde lista a los principales países que el Perú exporta con la cantidad y participación correspondiente desde el 2015 al 2019. Como se puede contrastar con la tabla 11, los países que están arriba en la lista son los países que también han demandado más al mercado y el Perú aprovechó por medio de los tratados del libre comercio y de su capacidad productora para tener un lugar en el mercado de la palta.

Tabla 11: Top 10 de países exportadores de palta en toneladas

	Volumen en miles TM					% part. 2019	CAGR 2015-2019	% Var 19/18
	2015	2016	2017	2018	2019			
<b>Total exportado</b>	175684	194084	247537	361362	312241		12.2%	-13.6%
<b>PAÍSES BAJOS</b>	65097	79705	92814	139606	107384	34.4%	10.5%	-23.1%
<b>ESTADOS UNIDOS</b>	47177	32253	66215	82910	85419	27.4%	12.6%	3.0%
<b>ESPAÑA</b>	31775	41745	41839	59509	48654	15.6%	8.9%	-18.2%
<b>REINO UNIDO</b>	17234	21303	24801	29736	25641	8.2%	8.3%	-13.8%
<b>CHILE</b>	8348	7992	6114	20945	16848	5.4%	151.0%	-19.6%
<b>CHINA</b>	59	1869	4633	11904	10258	3.3%	180.2%	-13.8%
<b>JAPÓN</b>	25	947	3270	5183	4524	1.4%	183.6%	-12.7%
<b>HONG KONG</b>	524	1933	1805	5212	3374	1.1%	45.1%	-35.3%
<b>RUSIA</b>	528	717	1094	1666	4256	1.4%	51.8%	155.4%
<b>CANADA</b>	1463	365	1514	757	1914	0.6%	5.5%	152.7%
<b>BÉLGICA</b>	342	492	363	513	1221	0.4%	29.0%	137.8%
<b>ALEMANIA</b>	63	398	43	233	813	0.3%	66.6%	249.7%
<b>COSTA RICA</b>	1694	3296	1861	2057	292	0.1%	-29.6%	-85.8%
<b>INDIA</b>	0	0	2	103	177	0.1%	335.8%	71.7%
<b>FRANCIA</b>	198	180	139	12	213	0.1%	1.5%	1709.0%
<b>PORTUGAL</b>	0	0	355	465	232	0.1%	-13.2%	50.0%
<b>MARRUECOS</b>	512	435	0	110	210	0.1%	-16.4%	90.4%
<b>ARABIA SAUDITA</b>	23	21	105	125	120	0.0%	39.5%	-4.3%
<b>UCRANIA</b>	0	0	0	0	148	0.0%		
<b>TURQUÍA</b>	0	0	0	0	128	0.0%		
<b>OTROS PAÍSES</b>	622	435	570	316	416	0.1%	-7.7%	32.0%

Fuente: Sierra Exportadora, MINAGRI (2020)



China y Japón también son buenos prospectos, aunque según la tabla 11 no ha crecido sus importaciones totales, tienen un gran crecimiento en las importaciones con Perú, en contraste con el periodo previo; Hong Kong al parecer llegó a una meseta. A partir de la información de la FAO y *Trademap* (una página que tiene información de importaciones y exportaciones detalladamente), se complementará el panorama para saber cómo es el comportamiento de los primeros 4 países de la lista, China y Japón en el tiempo.




Gráfico 12: Evolución de importaciones de Países Bajos, Japón, China, España, Reino Unido y Estados Unidos

Se ve un gran auge para Estados Unidos y un potencial mercado para incursionar más, Países bajo sigue creciendo pronunciado. Sin embargo, se debe analizar el consumo per cápita por país con buen prospecto de posible mercado para tener una idea de su posible crecimiento o si no va a aumentar mucho como parece que es el caso de España, Japón, China y Reino Unido, pero aún debe corroborarse. En el anexo 2 se mostrará el comportamiento en el tiempo con sus países con quienes importan, los puntos con una equis roja son debido a que no hay data sobre ese país.

### 3.4. La palta en el Perú

Ya se ha visto previamente sobre las importaciones y exportaciones a nivel mundial y en contraste con el Perú. Se tiene el enfoque en las importaciones con los países que el Perú tiene comercio y posibles mercados; además de las exportaciones del Perú para tener un panorama más adelante de cuánto es la brecha.

Acerca de las características del Perú con la palta, por medio de un mapa interactivo creado por el MINAGRI estudiando del año 2013 al 2018. Muestra diversos valores ordenados jerárquicamente por país, departamento, provincia y distrito, como porcentaje

de producción del total por mes, porcentaje de producción por un nivel mayor de jerarquía (por ejemplo, el porcentaje de participación de todos los distritos en la provincia), superficie utilizada en hectáreas por algún nivel de la jerarquía y rendimiento del suelo (toneladas/hectárea).

A continuación, se muestra el mapa mostrando con un color verde más intenso los departamentos con un mayor nivel de participación a nivel Perú

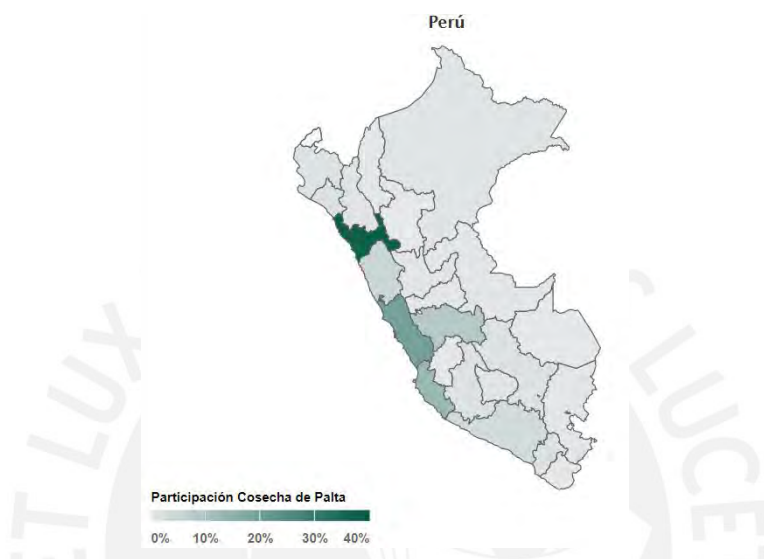


Figura 21: Mapa del Perú con nivel de intensidad según lo cosechado por Departamento

Fuente: MINAGRI (2020)

Según el gráfico anterior, La Libertad tiene 37.3%, Lima 19.5%, Ica 12.9%, Junín 8.2%, Ancash 4.8%, Arequipa 3.3% y el resto de los departamentos menos de 2%. Como también se puede notar, se tiene una gran participación de la palta en la costa. Esto también se debe a la cercanía a los puertos. En el 2014 el MTC, publicó un informe orientado a los productos agrícolas y su cadena logística, donde se muestra la siguiente figura que se basó en la información de la SUNAT y Declaración Aduanera de Mercancías (DAM).

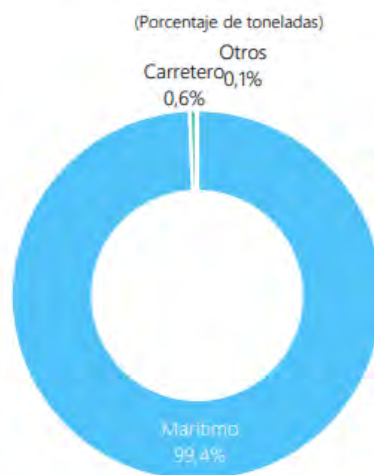


Figura 22: Distribución por modo de transporte - 2014

Fuente: MTC (2014)

Acerca del rendimiento promedio por departamento, se muestra en la siguiente tabla.

Tabla 12 : Rendimientos por provincia

Departamento	Rendimiento
Amazonas	8.1
Ancash	6.6
Apurímac	6.5
Arequipa	19.8
Ayacucho	5.6
Cajamarca	9.0
Cuzco	7.3
Huancavelica	8.9
Huánuco	8.7
Ica	15.3
Junín	10.3
La Libertad	14.4
Lambayeque	10.4
Lima	13.1
Loreto	10.5
Madre de Dios	8.1
Moquegua	6.5
Pasco	15.9
Puno	10.1
Piura	10.8
San Martín	12.5
Tacna	7.2
Ucayali	7.3
Tumbes	No hay información

### **3.5. Capacidad hídrica del Perú**

Más allá de saber las cualidades de rendimiento por distrito, es importante conocer la capacidad del lugar para poder desarrollar la agricultura, en este caso será de la capacidad hídrica. La entidad encargada en el Perú del monitoreo de este insumo es la Autoridad Nacional del Agua (ANA). ANA junto con *World Wide Fund*(WWF), MINAGRI y la Agencia Suiza para el Desarrollo y la Cooperación (COSUDE) realizaron un informe llamado “Huella hídrica del Perú. Sector agropecuario” en el año 2015.

#### **3.5.1. Huella hídrica**

Es un indicador que nos permite saber el volumen de agua requerido y nos permite saber si lo estamos usando de manera sostenible. Hay 2 tipos: directa e indirecta, el directo es cuando se emplea en el proceso de fabricación del bien, por ejemplo, cuando se elabora un tejido de algodón; mientras que el indirecto es cuando se riega a la planta de algodón y produzca algodón. Los indirectos suelen consumir mucho más que los directos.

#### **3.5.2. Tipo de extracciones**

Existen dos tipos, el consuntiva y no consuntiva; la consuntiva es cuando se incorpora a un producto o se devuelve a una fuente distinta o a la misma cuenca en otro momento posterior, y el no consuntiva es cuando no se extrae de la fuente, como en la pesca, campo energético, recreaciones, etc.

#### **3.5.3. Tipos de agua**

Existen tres tipos de agua: azul, verde y gris. Según el informe, el agua azul es cuando es extraída de una fuente natural, superficial o subterránea, se debe almacenar y distribuir para ser entregada al usuario final, por lo tanto, tiene un costo. El agua verde es el sacado del suelo no saturado mojado por la lluvia y donde las plantas pueden absorberlo, su costo es casi nulo ya que no tiene un costo de almacenamiento ni transporte. Por último, el agua gris es el volumen teórico de agua dulce que se requiere para poder diluir la carga contaminante en un área y pueda entrar en los estándares de calidad del agua del lugar.

#### **3.5.4. Disponibilidad de agua**

Según el informe, el Perú se encuentra dentro de los 10 países con mayores reservas de agua en el mundo. Sin embargo, hace una acotación, el Perú tiene diferencias hidrológicas extremas, la vertiente del Atlántico representa un 70% del territorio peruano y tiene altos niveles de precipitaciones anuales, aproximadamente el 98% del agua disponible en el Perú es de esta vertiente, pero tiene poca densidad poblacional y bajo desarrollo industrial. En contra parte, la vertiente del Pacífico representa un 2% aproximadamente de los

recursos hídricos y un 63% de la población nacional está en esta área; además de que las actividades económicas del país que otorgan un 80% del PBI están. Por último, está la vertiente del Titicaca, con un 0.3% del agua disponible en el Perú y el 4% de la población. El Perú anualmente tiene un volumen promedio de agua de 1,768,73 metros cúbicos.

A continuación, se colocará una imagen de la distribución del agua y población según las vertientes del Perú.



Figura 23: Distribución de recursos hídrico a nivel nacional

Fuente: ANA, WWF, MINAGRI, Agencia Suiza y UNALM (2015)

Para tener un panorama visual de y cuantificable, se colocará el gráfico 12 y tabla 13 con los valores numéricos de un informe acerca el aprovechamiento del agua en metros cúbicos por habitante y que fue en base a la información de la ONERN para el año 1985, DGAS para el 1992 y ANA para el 2013.

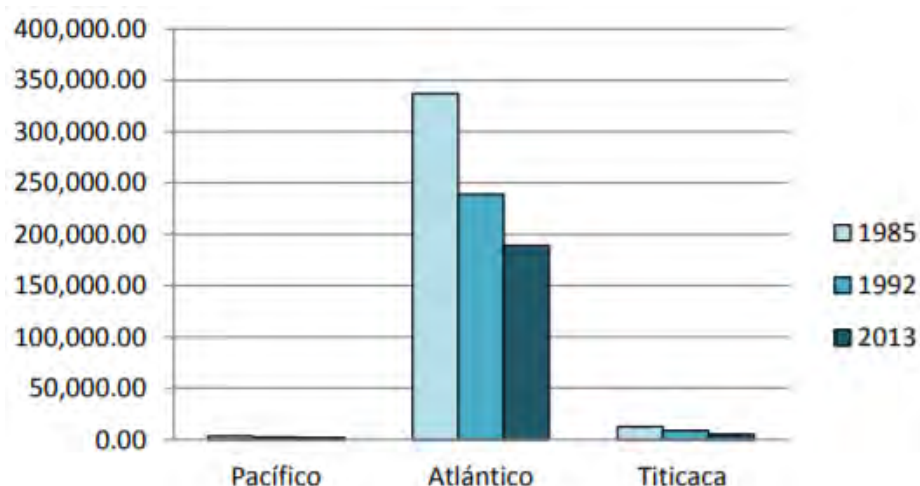


Gráfico 13: Relación de disponibilidad de agua por población (m³/hab.) por vertiente hidrográfica (1985; 1992 y 2013)

Fuente: Capítulo 3 Aprovechamiento Del Agua: Nicole Bernex, Katusca Yakabi, Álvaro Zúñiga, Lizet Asto y Carlos Verano

La tabla 15, si bien no es una tabla que se pueda utilizar, da una idea de la abundancia del recurso hídrico por vertiente. A partir de ella si bien la población está concentrada en la costa, se ve que hay un exceso de agua en la vertiente del Atlántico notoria en contraste con la del Pacífico y Titicaca. Sería cuestión de realizar una cuantificación más detallada y proyectar a 5 años para tener una confianza de qué tanto podría abastecer la vertiente y llegar a una capacidad hídrica a nivel distrital.

Tabla 13: Relación de disponibilidad vs población

Vertiente	Relación disponibilidad vs población (m³/hab)		
	1985	1992	2013
Pacífico	3370.0	2390.0	1815.6
Atlántico	336980.0	239083.0	189167.2
Titicaca	12423.0	8813.0	5019.4
TOTAL	120032.0	85161.4	64376.5

Por otro lado, se mostrará para el año 2016 cómo está el uso del agua por área geográfica en el Perú y el uso predominante de actividad en colores que fue realizado por ANA. Es muy importante como indicador para usarlo como indicador en el futuro modelo matemático que se planteará como mejor a esta problemática.

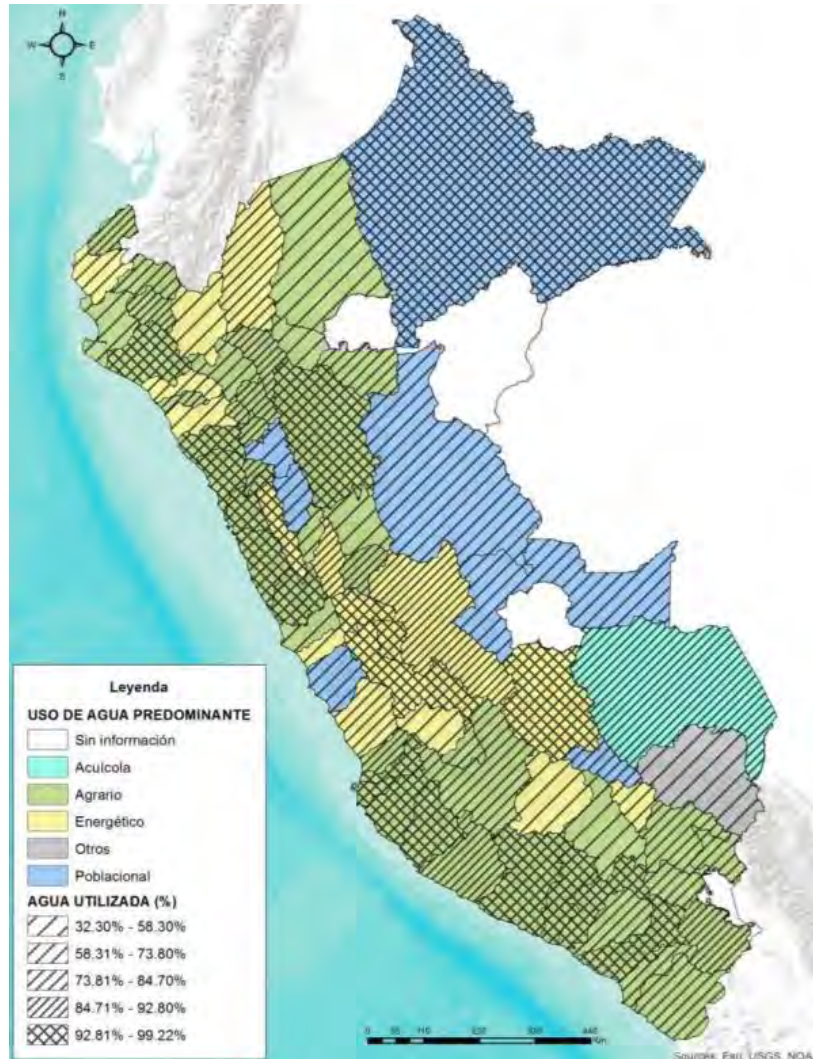



Figura 24: Uso de agua predominante por Administración Local de Agua y porcentaje de agua utilizado para dicho uso

Fuente: ANA (2016)

Se ve una gran saturación en la costa, en ciertas áreas de la sierra y en Loreto parte alta. A partir de la información de las fuentes investigadas se realizó varias tablas proyectando para el 2025 cómo estará la capacidad hidrológica en el Perú. Se dividió en consuntivo y no consuntivo, en el tipo no consuntivo gran porcentaje es por parte de la energía como se ve en la tabla 16, se calculará la proporción por zonas del consumo por las hidroeléctricas y se dividirá el total de consumo para el 2025 de no consuntivo en función de esos porcentajes de la tabla 28 de lo proyectado en la tabla 27.

Figura 25: Evolución de consuntivo y no consuntivo



Fuente: Capítulo 3 Aprovechamiento Del Agua: Nicole Bernex, Katusca Yakabi, Álvaro Zúñiga, Lizet Asto y Carlos Verano

Tabla 14: Consumo no consuntivo 2009 y 2016

Año	Acuícola (hm³)	Energético (hm³)	Med, rec,tur,trans. (hm³)	Total (hm³)
2009	-	11139	-	-
2016	467122	29402971	64659	29934751

Tabla 15: Proyección de no consuntivo

No Consuntivo				
Vertiente	Consumo (hm³)	Crecimiento porcentual anual	Crecimiento promedio anual	Consumo para el 2025 (hm³)
1984	11,139.00		5%	47,784.71
2012	23,637.26	4%		
2016	29,934.75	7%		

Tabla 16: Consumo por vertiente a partir de hidroeléctricas

Consumo por hidroeléctricas del 2013 (hm³)					
Autoridad Administrativa de Agua	Consumo (hm³/año)	Porcentaje del total	Vertiente	Consumo no consuntivo 2025 en función del porcentaje total	Consumo no consuntivo por vertiente
Caplina-Ocoña	643.29	2.82%	Pacífico	1,349.23	18,880.22
Chaparra-Chincha	0.00	0.00%	Pacífico	0.00	
Cañete-Fortaleza	5,045.48	22.15%	Pacífico	10,582.37	
Huarmey-Chicama	547.48	2.40%	Pacífico	1,148.28	
Jequetepeque-Zarumilla	2,765.49	12.14%	Pacífico	5,800.33	
Marañón	1,097.82	4.82%	Atlántico	2,302.56	28904.50
Amazonas	0.00	0.00%	Atlántico	0.00	
Huallaga	903.36	3.97%	Atlántico	1,894.70	
Ucayali	4,150.69	18.22%	Atlántico	8,705.64	
Mantaro	6,516.00	28.60%	Atlántico	13,666.64	
Pampas-Apurímac	482.54	2.12%	Atlántico	1,012.08	
Urubamba-Vilcanota	0.00	0.00%	Atlántico	0.00	
Madre de Dios	630.72	2.77%	Atlántico	1,322.87	
Titicaca	0.00	0.00%	Titicaca	0.00	



Para el consuntivo se han realizado también tablas a partir de la información de los informes. En la tabla 21 se mostrará el consumo y el crecimiento porcentual para que en la tabla 21 se pueda proyectar el consumo consuntivo para el 2025

Tabla 17: Uso consuntivo por vertiente

Volumen en hm <sup>3</sup> por uso consuntivo						
Vertientes	Poblacional			Agrario		
	1992	2016	Crecimiento promedio	1992	2016	Crecimiento promedio
Pacífico	1,018.00	2,007.42	4.05%	14,228.00	13,196.17	-0.30%
Atlántico	228.00	9.87	13.87%	2,037.00	4,227.52	4.58%
Titicaca	18.00	0.35	3.91%	81.00	329.76	12.80%
Vertientes	Industrial			Minero		
	1992	2016	Crecimiento promedio	1992	2016	Crecimiento promedio
Pacífico	1,103.00	2,358.04	4.74%	152.00	340.61	5.17%
Atlántico	49.00	189.22	11.92%	53.00	315.73	20.65%
Titicaca	3.00	0.98	-2.81%	2.00	18.59	34.56%

Tabla 18: Uso consuntivo por rubro necesario para el 2025

Consuntivo proyectado para el 2025					
Vertientes	Poblacional (hm <sup>3</sup> )	Agrario(hm <sup>3</sup> )	Industrial (hm <sup>3</sup> )	Minero (hm <sup>3</sup> )	Total (hm <sup>3</sup> )
Pacífico	2,448.17	12,998.00	2972.59	438.25	18,857.01
Atlántico	1,889.62	5,351.76	332.33	807.32	8,381.03
Titicaca	42.23	602.10	0.85	82.02	727.20

A partir de todo este consumo consuntivo y no consuntivo se hará una proyección y viendo cómo estaría la capacidad hídrica de cada vertiente.

Tabla 19: Recurso hídrico disponible para el 2025

Vertientes	Volumen escurrido (hm <sup>3</sup> ) 2013	Total consuntivo (hm <sup>3</sup> )	Total no consuntivo (hm <sup>3</sup> )	Total disponible (hm <sup>3</sup> )
Pacífico	34,136.00	18,857.01	18,880.22	-3601.23
Atlántico	1,895,226.00	8,381.03	28,904.50	1,857,940.48
Titicaca	6,259.00	727.20	0.00	5531.80

Como se ven se tiene un negativo disponible en el Pacífico si sigue creciente como ha estado creciendo en promedio. Sin embargo, en el consumo no consuntivo como se ha mencionado previamente es por parte de energía. Pero según el capítulo 3 de "Aprovechamiento del agua", comenta lo siguiente "Este último punto es precisamente el principal problema relacionado con la generación de energía hidroeléctrica. La mayoría de las centrales hidroeléctricas en el Perú son "de paso". Esto significa que se capta agua directamente del río, sin ser almacenada en una cantidad significativa, y es derivada a la central. El agua usada para generación se devuelve al curso de agua (o a otro) aguas abajo. Esto significa que la producción de energía en el Perú es muy vulnerable a las sequías, aunque se han construido nuevas centrales térmicas en los últimos años debido

a la alta demanda de energía. Por lo tanto, hay una necesidad inmediata de aumentar la capacidad de generación de energía.”. No hay información acerca de la proporción de cuánto del total sí retiene y cuánto; por lo tanto, en esta investigación se optará por tomar la vertiente del Atlántico y Titicaca para poder crecer en la agricultura de la palta al haber una holgura.

El consumo de agua por hectárea del agua según la página Portal del Campo, la palta tiene un rango de consumo de 16,000 a 7,000 metros cúbicos de agua por hectárea al año, se tomará que consume por hectárea unos 12,500 metros cúbicos y así uniformizar el análisis. Para tener una idea de la conversión de hectómetro cúbico (hm<sup>3</sup>) a metros cúbicos (m<sup>3</sup>), 1 hectómetro cúbico equivale a 1,000,000 metros cúbicos.

A continuación, en la tabla se muestra los distritos con sus respectivas provincias y departamentos donde la vertiente del Atlántico abastece. Se muestra los hectómetros cúbicos disponibles y cuántas hectáreas abastecería.

Tabla 20: Hectáreas disponibles por distrito abastecidos por la vertiente del Atlántico

Departamento	Provincia	Distrito	Superficie del departamento (ha)	Superficie total para la vertiente del Atlántico (ha)	Superficie del distrito (ha)	Total disponible (hm <sup>3</sup> )	Hectareas abastecidas
Amazonas	Bagua	La Peca	3,924,913	92,468,855	29,139.00	585	46,838.28
Amazonas	Rodriguez de Mendoza	Cochamal	3,924,913	92,468,855	21,300.00	428	34,237.80
Amazonas	Bagua	Bagua	3,924,913	92,468,855	7,500.00	151	12,055.57
Apurímac	Abancay	Curahuasi	2,089,600	92,468,855	86,600.00	1,740	139,201.59
Apurímac	Graú	Curpahuasi	2,089,600	92,468,855	31,100.00	625	49,990.41
Apurímac	Andahuaylas	Huayana	2,089,600	92,468,855	9,687.00	195	15,570.97
Ayacucho	Huamanga	Ayacucho	4,381,480	92,468,855	8,529.00	171	13,709.59
Ayacucho	Huamanga	Carmen Alto	4,381,480	92,468,855	1,933.00	39	3,107.12
Ayacucho	Huamanga	Pacaycasa	4,381,480	92,468,855	41,800.00	840	67,189.68
Ayacucho	Lucanas	Chaviña	4,381,480	92,468,855	37,200.00	747	59,795.60
Ayacucho	Huanta	Huanta	4,381,480	92,468,855	35,500.00	713	57,063.01
Cajamarca	Cajabamba	Cachachi	3,330,430	92,468,855	81,500.00	1,638	131,003.81
Cajamarca	Cajabamba	Cajabamba	3,330,430	92,468,855	19,000.00	382	30,540.76
Cajamarca	Contumaza	San Benito	3,330,430	92,468,855	48,660.00	978	78,216.51
Cuzco	Paruro	Accha	7,198,650	92,468,855	24,480.00	492	39,349.36
Cuzco	Paruro	Ccapi	7,198,650	92,468,855	33,480.00	673	53,816.04
Cuzco	La Convención	Pichari	7,198,650	92,468,855	73,040.00	1,468	117,405.13
Huancavelica	Castrovirreyña	Arma	2,213,147	92,468,855	30,480.00	612	48,993.82
Huancavelica	Churcampá	Churcampá	2,213,147	92,468,855	14,140.00	284	22,728.76
Huancavelica	Tayacaja	Colcabamba	2,213,147	92,468,855	59,810.00	1,202	96,139.11
Huánuco	Huamalies	Jacas Grande	3,702,107	92,468,855	23,699.00	476	38,093.98
Huánuco	Pachitea	Chaglla	3,702,107	92,468,855	66,452.00	1,335	106,815.52
Huánuco	Puerto Inca	Puerto Inca	3,702,107	92,468,855	207,100.00	4,161	332,894.34
Junín	Satipo	Satipo	4,432,880	92,468,855	73,200.00	1,471	117,662.31
Junín	Jauja	Molinos	4,432,880	92,468,855	31,220.00	627	50,183.30
Loreto	Maynas	Indiana	36,879,948	92,468,855	329,800.00	6,627	530,123.38
Loreto	Loreto	Parinari	36,879,948	92,468,855	109,400.00	2,198	175,850.51
Madre de Dios	Tahuamanu	Iñapari	8,530,054	92,468,855	1,485,366.00	29,845	2,387,590.18
Madre de Dios	Tambopata	Tambopata	8,530,054	92,468,855	2,067,700.00	41,545	3,323,638.90
Madre de Dios	Tahuamanu	Ibeia	8,530,054	92,468,855	254,900.00	5,122	409,728.47
Pasco	Oxapampa	Oxapampa	2,502,584	92,468,855	41,980.00	843	67,479.02
San Martín	Mariscal Cáceres	Huicungo	5,130,578	92,468,855	979,900.00	19,689	1,575,099.75
San Martín	Lamas	Lamas	5,130,578	92,468,855	9,600.00	193	15,431.12
San Martín	Tocache	Tocache	5,130,578	92,468,855	111,700.00	2,244	179,547.55
Ucayali	Coronel Portillo	Masisea	10,239,994	92,468,855	1,410,200.00	28,335	2,266,767.70
Ucayali	Atalaya	Sepahua	10,239,994	92,468,855	771,500.00	15,501	1,240,115.79
Ucayali	Coronel Portillo	Nueva Requena	10,239,994	92,468,855	224,900.00	4,519	361,506.21

No aparece Puno debido a que no se encuentra la data disponible para realizar el trabajo completo.

### 3.6 Superficie agrícola disponible

El segundo recurso para calcular por distrito es la superficie disponible. Se tomará la superficie agrícola no trabajada como la superficie agrícola disponible. Según el IV Censo Nacional Agropecuario 2012 hecho por el INEI, las principales razones por la que no se trabaja el área son las siguientes.

Tabla 21: Razones por la que no se trabaja la superficie agrícola

Razón principal	Total	Estructura %	Región natural		
			Costa	Sierra	Selva
Total	774,882.24	100.0%	301,463.84	237,721.78	235,705.62
Falta de agua	378,912.23	48.9%	207,826.53	122,923.67	48,162.04
Falta de semilla	32,491.35	4.2%	2,929.24	17,612.65	11,949.46
Falta de crédito	186,386.05	24.1%	41,740.40	40,403.12	104,242.54
Falta de mano de obra	87,866.64	11.3%	11,274.91	31,419.84	45,171.89
Por sanidad, erosión	38,653.52	5.0%	19,308.17	13,070.39	6,274.97
Consiguió otro trabajo	5,752.25	0.7%	927.09	1,850.27	2,974.89
Robo	2,095.75	0.3%	1,662.21	220.14	213.40
Por terrorismo	355.37	0.0%	1.25	99.29	254.80
Por desastre natural	14,480.85	1.9%	3,467.16	4,088.99	6,924.70
Otra	27,888.23	3.6%	12,326.86	12,326.86	9,536.93

En magnitud la principal es la falta de agua según la encuesta en el 2012; sin embargo, en la teoría se ve que hay agua en los distritos. Según una breve entrevista a un jefe de un fundo de la empresa CasaBlanca, comenta que hay casos donde hay canales naturales en el campo donde siembra; sin embargo, hay casos donde no y se debe consultar con la Autoridad del agua de la zona para poder extraer del río. Lo más probable es que la falta de agua sea porque no se ha podido hacer el trámite o porque como agricultor individual no le salía rentable realizar el coste de construcción de tuberías o creación de canales para el terreno planeado.

Para calcular la cantidad de superficie no agrícola por distrito, se realizó una aproximación. El INEI tiene la superficie agrícola y la agrícola no trabajada por departamento, a partir de ahí se sacó el porcentaje de superficie agrícola no trabajada en función de la superficie agrícola por departamento. Por medio del SIEA MIDAGRI, se obtuvo la superficie agrícola por distrito; a partir de la superficie agrícola por distrito se multiplicó el porcentaje que se

había calculado previamente que era por departamento, el valor hallado sería la superficie agrícola no trabajada por distrito. La tabla 22 muestra los valores hallados, que vendría a ser las hectáreas libres para poder realizar la actividad agrícola.

Tabla 22: Superficie agrícola disponible por distrito

Índice	Departamento	Provincia	Distrito	Porcentaje del departamento de tierra agrícola no trabajada (2018)
1	Amazonas	Bagua	La Peca	19%
2	Amazonas	Rodriguez de Mendoza	Cochamal	19%
3	Amazonas	Bagua	Bagua	19%
4	Apurímac	Abancay	Curahuasi	17%
5	Apurímac	Graú	Curpahuasi	17%
6	Apurímac	Andahuaylas	Huayana	17%
7	Ayacucho	Huamanga	Ayacucho	21%
8	Ayacucho	Huamanga	Carmen Alto	21%
9	Ayacucho	Huamanga	Pacaycasa	21%
10	Ayacucho	Lucanas	Chaviña	21%
11	Ayacucho	Huanta	Huanta	21%
12	Cajamarca	Cajabamba	Cachachi	17%
13	Cajamarca	Cajabamba	Cajabamba	17%
14	Cajamarca	Contumaza	San Benito	17%
15	Cuzco	Paruro	Accha	10%
16	Cuzco	Paruro	Ccapi	10%
17	Cuzco	La Convención	Pichari	10%
18	Huancavelica	Castrovirreyna	Arma	10%
19	Huancavelica	Churcampa	Churcampa	10%
20	Huancavelica	Tayacaja	Colcabamba	10%
21	Huánuco	Huamalies	Jacas Grande	29%
22	Huánuco	Pachitea	Chaglla	29%
23	Huánuco	Puerto Inca	Puerto Inca	29%
24	Junín	Satipo	Satipo	38%
25	Junín	Jauja	Molinos	38%
26	Loreto	Maynas	Indiana	46%
27	Loreto	Loreto	Parinari	46%
28	Madre de Dios	Tahuamanu	Iñapari	39%
29	Madre de Dios	Tambopata	Tambopata	39%
30	Madre de Dios	Tahuamanu	Ibeia	39%
31	Pasco	Oxapampa	Oxapampa	23%
32	San Martín	Mariscal Caceres	Huicungo	31%
33	San Martín	Lamas	Lamas	31%
34	San Martín	Tocache	Tocache	31%
35	Ucayali	Coronel Portillo	Masisea	38%
36	Ucayali	Atalaya	Sepahua	38%
37	Ucayali	Coronel Portillo	Nueva Requena	38%

Al igual que en el agua, tampoco se puso a Puno debido a la misma razón mencionada.

### 3.7 Informalidad y pobreza

El Peruano publicó que según el Banco Mundial la actividad agrícola genera 1 de cada 4 empleos formales en el Perú y también es uno de los pilares contra la pobreza en el Perú. Estas conclusiones fueron a partir del libro “Tomando impulso en la agricultura peruana. Oportunidades para aumentar la productividad y mejorar la competitividad del sector”. La informalidad es un tema que está presente y es conocido por todos. Según el INEI, antes

de la pandemia, el 73% de los trabajadores eran informales, en la tabla 23 se muestra el porcentaje de informalidad por departamento según el INEI en el 2018.

Tabla 23: Porcentaje de informalidad por departamento

Departamento	Porcentaje de informalidad
Amazonas	85.35%
Áncash	80.33%
Apurímac	88.04%
Arequipa	65.27%
Ayacucho	87.10%
Cajamarca	89.34%
Prov. Const. del Callao	56.07%
Cusco	81.61%
Huancavelica	91.41%
Huánuco	87.30%
Ica	61.10%
Junín	83.48%
La Libertad	72.55%
Lambayeque	74.17%
Lima	58.59%
Loreto	81.80%
Madre de Dios	76.16%
Moquegua	64.40%
Pasco	80.90%
Piura	78.33%
Puno	87.57%
San Martín	84.63%
Tacna	74.19%
Tumbes	75.96%
Ucayali	77.58%

Se corrobora visualmente que el promedio se aproxima al valor dado por el INEI, es importante potenciar el trabajo formal en los lugares donde la informalidad es alta; por ejemplo, Huancavelica tiene un 91.41% de informalidad con Apurímac con un 88.04% serían los departamentos con mayor grado de informalidad y los menores serían el Callao y Lima con 56.07% y 58.59% respectivamente. Ya que la actividad agrícola combate esta problemática más adelante se tomará como un indicador, se colocarán a los distritos los valores de sus departamentos respectivos como una aproximación para saber su grado de informalidad.

Por otro lado, está la pobreza, que al igual que la informalidad es combatida por la actividad agrícola y se tomará como indicador en el modelo matemático para asignar a los distritos y su producción. En la ilustración siguiente se muestra el mapa del Perú mostrando el rango de pobreza por departamento, al igual que con la informalidad se tomará este valor para los valores de los distritos como una aproximación; si bien es un rango se tomará el valor medio para cuantificarlo.



Figura 25: Mapa de porcentaje de pobreza 2018

Fuente: INEI (2018)

## CAPÍTULO 4: PROPUESTA DE MEJORA

La propuesta de mejora se basará en tres puntos: la descripción de los distritos según su clima para posiblemente encontrar un *insight* acerca de los mismos, realizar un análisis y proyecciones para un año a partir de julio del 2020 hasta julio del 2021 y poder encontrar mercados para la palta en los países potenciales para exportación y formular un modelo matemático que tome busque maximizar la exportación posible por meses según los recursos e indicadores mencionados previamente. Esto buscar desarrollar una metodología óptima con un impacto no solamente en lo económico como país sino también en lo social y económico a nivel distrital y así poder mejorar la calidad de vida de las personas de la zona.

### 4.1 Características climáticas de los distritos

Se extrajo la información de *Weather Spark*, es una página que muestra el comportamiento climático de diversos países hasta a nivel distrital. A partir del mapa SIEA MIDAGRI, se seleccionan los distritos donde haya información del clima, seleccionando los 2 a 4 distritos que tengan un mayor rendimiento del terreno con la palta. A continuación, se muestra la página de SIEA MIDAGRI.

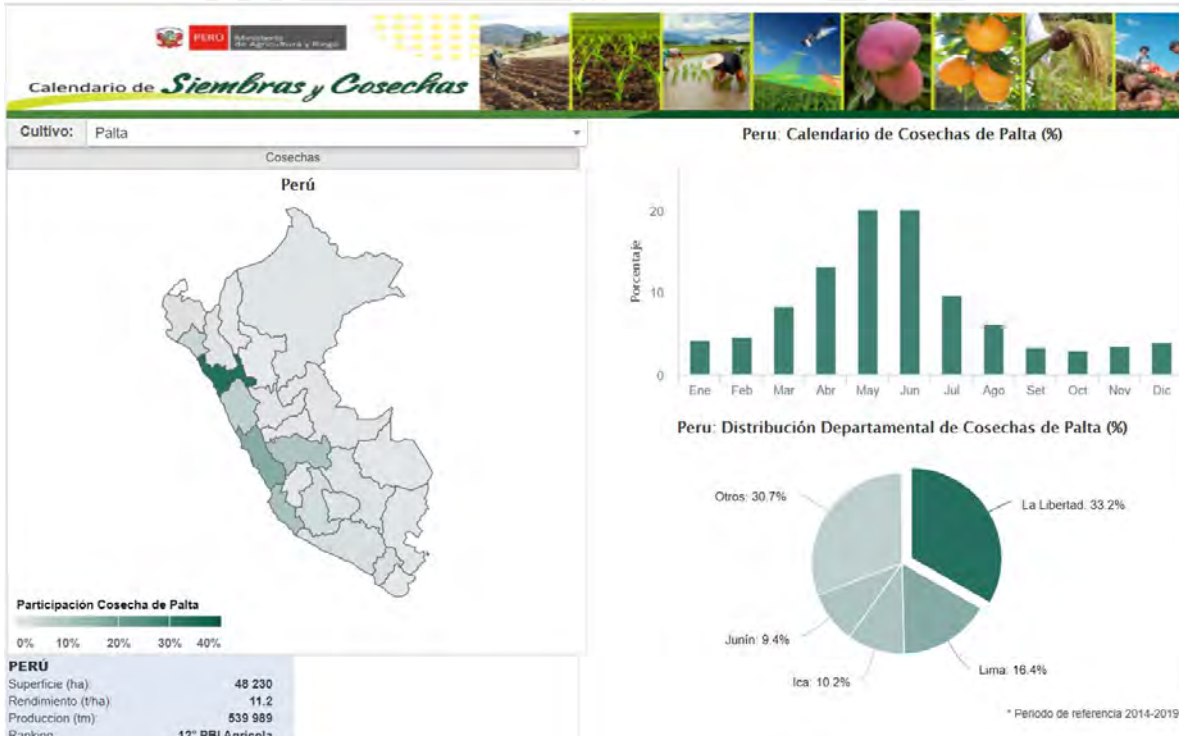


Figura 26: Datos de la palta

Fuente: SIEA MIDAGRI (2020)

Se obtuvo del *Weather Spark* los siguientes datos de manera mensual: Temperatura media, temperatura máxima, temperatura mínima, precipitación (mm), altura sobre el nivel del mar (m), viento (km/h), energía solar(kWh) y proporción de nubes. La razón por la cual se tomaron los anteriores datos es debido a la disponibilidad de los datos y detalle que se busca para determinar cuantitativamente el clima “promedio” que tiene una zona distrital.

Sin embargo, para realizar el análisis de Análisis de Principales Componentes se transformó por distrito a las siguientes medidas: Valor promedio, desviación estándar y coeficiente de variación.

Luego de realizar el análisis se mantuvieron los que eran más significativos contrastando el rendimiento que tiene cada distrito según la información del MINAGRI y conforme a la información disponible de *Weather Spark*.

Tabla 24: Distritos que se analizaron

Departamento	Provincia	Distrito
Amazonas	Bagua	La Peca
Amazonas	Rodriguez de Mendoza	Cochamal
Amazonas	Bagua	Bagua
Apurímac	Abancay	Curahuasi
Apurímac	Graú	Curpahuasi
Apurímac	Andahuaylas	Huayana
Ayacucho	Huamanga	Ayacucho
Ayacucho	Huamanga	Carmen Alto
Ayacucho	Huamanga	Pacaycasa
Ayacucho	Lucanas	Chaviña
Ayacucho	Huanta	Huanta
Cajamarca	Cajabamba	Cachachi
Cajamarca	Cajabamba	Cajabamba
Cajamarca	Contumaza	San Benito
Cuzco	Paruro	Accha
Cuzco	Paruro	Ccapi
Cuzco	La Convención	Pichari
Huancavelica	Castrovirreyña	Arma
Huancavelica	Churcampa	Churcampa
Huancavelica	Tayacaja	Colcabamba
Huánuco	Huamalies	Jacas Grande
Huánuco	Pachitea	Chaglla
Huánuco	Puerto Inca	Puerto Inca
Junín	Satipo	Satipo
Junín	Jauja	Molinos
Loreto	Maynas	Indiana
Loreto	Loreto	Parinari
Madre de Dios	Tahuamanu	Iñapari
Madre de Dios	Tambopata	Tambopata
Madre de Dios	Tahuamanu	Ibeia
Pasco	Oxapampa	Oxapampa
San Martín	Mariscal Caceres	Huicungo
San Martín	Lamas	Lamas
San Martín	Tocache	Tocache
Ucayali	Coronel Portillo	Masisea
Ucayali	Atalaya	Sepahua
Ucayali	Coronel Portillo	Nueva Requena
Lima	Huarua	Huarua
Piura	Piura	Piura
Lambayeque	Lambayeque	Olmos
Áncash	Santa	Chimbote
Áncash	Casma	Casma
Ica	Ica	Ica
Ica	Chincha	El Carmen
Moquegua	Mariscal Nieto	Torata
Tacna	Jorge Basadre	Locumba
La Libertad	Viru	Viru
Arequipa	Arequipa	Uchumayo
Arequipa	Arequipa	Tiabaya



Luego de la aplicación del algoritmo de Principales Componentes de Análisis (PCA) se logra obtener el gráfico 13 el cual muestra la posición relativa de los distritos en los principales componentes, los más cercanos son los que se parecen más en función de todas las variables. El grado de color indica el rendimiento, el que tenga un color más rojizo tendrá un valor más alto de rendimiento y el de un color más celeste es el de un menor




Gráfico 14: Distritos en el gráfico de principales componentes

valor.

Los nombres están en el formato “Departamento – Distrito”; por otro lado, se puede ver que en la esquina superior izquierda se ven los distritos que están en la selva, es razonable porque tiene un clima muy parecido, se ve que tiene un rendimiento parecido. Por la parte superior derecha se ve que se agrupa la costa, al igual que la selva se ve que tiene un rango similar por excepción de algunos como Moquegua o Tacna, es posible su bajo rendimiento ya que no se trabaja mucho con la palta. Ahora, por la parte baja central se agrupan los que están en la sierra, se ve algo interesante con su comportamiento, ya que sus colores son muy variados; pero el que más resalta es el distrito de Ayacucho ya que tiene un rendimiento muy alto, se podría decir que el más alto. Esto lleva a una pregunta muy interesante “¿Es posible que se tenga un potencial muy alto a los distritos que están muy cercanos al distrito de Ayacucho en el mapa?”.

Para comprender visualmente más fácil se colocará un dendograma dividido en la cantidad de *cluster* según el *elbow method* para saber la cantidad de *cluster* deberían ser realizados.




Gráfico 15: *Elbow method* para la selección de cantidad de *cluster*

Se ve a partir de la cantidad de 7, una disminución no significativa en la suma de cuadrados de los errores, debido al cambio de pendiente que se nota se le llama el método del codo, en español. Ahora se mostrará el dendograma en el gráfico 15 para tener una idea de cuáles distritos se comportan más parecido.



Gráfico 16: Dendograma de los distritos

## 4.2 Potenciales mercados para exportar

A partir de la lectura del reporte de MIDAGRI realizado en enero del 2019 y junto a la recolección de datos otorgados por *Trademap*, se eligieron países representantes, viendo las exportaciones de Perú y por su presencia en el mundo, a Estados Unidos y Países Bajos porque ocupan más del 50% de exportaciones en el mundo y más del 50% de las exportaciones de Perú con la palta.

Tabla 25: Porcentaje por año de los países según las exportaciones mundiales

País	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
Estados Unidos	24%	24%	30%	34%	31%	41%	33%	47%	44%	50%	41%	46%	47%	48%	70%	52%	47%	46%	45%	45%
Países Bajos	6%	7%	7%	7%	6%	8%	8%	8%	10%	10%	13%	12%	11%	12%	14%	11%	13%	14%	15%	15%
Francia	32%	32%	25%	22%	22%	16%	16%	15%	13%	9%	11%	10%	9%	8%	0%	7%	7%	7%	7%	7%
Reino Unido	7%	7%	7%	6%	6%	9%	10%	6%	5%	4%	4%	4%	4%	3%	5%	4%	5%	5%	5%	5%
Japón	4%	3%	3%	6%	6%	4%	5%	4%	3%	3%	5%	4%	6%	5%	6%	3%	4%	3%	3%	3%
España	1%	2%	1%	3%	3%	3%	5%	3%	6%	4%	4%	3%	3%	3%	5%	4%	5%	5%	6%	6%
Canadá	4%	4%	4%	4%	4%	3%	4%	3%	3%	3%	4%	4%	5%	5%	0%	4%	4%	4%	4%	4%
Alemania	3%	4%	4%	4%	3%	3%	3%	3%	3%	2%	3%	3%	3%	3%	0%	3%	3%	4%	4%	4%
Suecia	2%	1%	1%	1%	2%	1%	1%	1%	2%	1%	2%	2%	2%	2%	0%	1%	1%	1%	1%	1%
Bélgica	3%	2%	3%	1%	1%	1%	1%	1%	1%	0%	1%	1%	1%	1%	0%	1%	2%	1%	1%	1%
El Salvador	3%	3%	3%	3%	3%	1%	2%	1%	1%	1%	1%	1%	1%	1%	0%	1%	1%	0%	0%	0%
Australia	1%	1%	1%	1%	1%	1%	2%	1%	1%	1%	1%	2%	1%	1%	0%	1%	1%	1%	1%	1%
Dinamarca	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	0%	1%	1%	1%	1%	1%
Colombia	3%	2%	3%	3%	4%	3%	3%	2%	1%	1%	1%	1%	0%	0%	0%	0%	0%	0%	0%	0%
Italia	1%	0%	0%	1%	1%	1%	1%	1%	0%	3%	3%	2%	0%	0%	0%	0%	1%	1%	1%	1%
China Occidental	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	1%	2%	2%
Rusia	0%	0%	0%	0%	0%	0%	1%	1%	1%	1%	1%	1%	1%	1%	0%	1%	0%	1%	1%	1%
Costa Rica	2%	2%	2%	1%	2%	1%	2%	1%	1%	1%	1%	1%	1%	1%	0%	0%	0%	0%	0%	0%
Suiza	1%	1%	1%	1%	1%	1%	1%	1%	1%	0%	1%	1%	0%	0%	1%	1%	1%	0%	0%	1%
Honduras	1%	1%	1%	1%	2%	1%	2%	1%	1%	1%	1%	0%	1%	0%	0%	1%	0%	0%	0%	0%
Arabia Saudita	1%	0%	1%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	1%	0%	1%	1%	1%	1%	1%
Emiratos Árabes Unidos	0%	0%	1%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	0%	1%	1%	1%	1%	1%
Marruecos	0%	0%	0%	0%	1%	1%	1%	1%	1%	1%	1%	1%	1%	1%	0%	0%	0%	0%	0%	0%
China, Hong Kong	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	1%	1%	1%
Argentina	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	1%	1%	1%	0%	0%	1%	1%	1%	0%
Polonia	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	1%
Noruega	0%	0%	0%	0%	0%	0%	0%	0%	1%	0%	0%	1%	0%	1%	0%	1%	0%	0%	0%	0%
Guatemala	1%	1%	1%	1%	1%	1%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
Chile	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%
México	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	1%	0%	0%	0%	0%	0%	0%	0%	0%	0%

Fuente: FAO-STAT (2019)

Tabla 26: Países a donde exporta Perú, los 15 más representativos

País de destino	2013	2014	2015	2016	2017	2018	2019
Países Bajos	44.00%	32.54%	37.07%	41.07%	37.49%	38.63%	34.39%
Estados Unidos	18.96%	36.38%	26.84%	16.62%	26.75%	22.94%	27.36%
España	25.15%	19.44%	18.08%	21.50%	16.90%	16.47%	15.58%
Reino Unido	5.44%	5.81%	9.81%	10.97%	10.02%	8.23%	8.21%
Chile	0.68%	1.53%	4.75%	4.12%	2.47%	5.80%	5.40%
China occidental	0.02%	0.00%	0.03%	0.96%	1.87%	3.29%	3.29%
Japón	0.00%	0.03%	0.01%	0.49%	1.32%	1.43%	1.45%
Rusia	0.33%	0.22%	0.30%	0.37%	0.44%	0.46%	1.36%
China, Hong Kong	0.55%	0.67%	0.30%	1.00%	0.73%	1.44%	1.08%
Canadá	2.27%	2.32%	0.83%	0.19%	0.61%	0.21%	0.61%
Bélgica	0.06%	0.22%	0.19%	0.25%	0.15%	0.14%	0.39%
Alemania	0.16%	0.12%	0.04%	0.20%	0.02%	0.06%	0.26%
Costa Rica	0.04%	0.06%	0.19%	1.70%	0.75%	0.57%	0.09%
Portugal	0.04%	0.02%	0.00%	0.00%	0.14%	0.13%	0.07%
Francia	1.94%	0.17%	0.11%	0.09%	0.06%	0.00%	0.07%

Fuente: Data Comex

### 4.2.1 China

Por otro lado, se ve como potencial mercado a China debido a su gran población y a su crecimiento notorio durante estos últimos años se ha disparado sus exportaciones de palta

y al parecer no tiene un país definido como exportador. En el gráfico 16 se puede ver su comportamiento como país. Por otro lado, en el reporte del MIDAGRI “La Situación del




Gráfico 17: Importaciones de China por año-mes y países de los países más representativos

Mercado Internacional de la Palta” realizado en el 2019, dice que es un producto poco conocido en China y, por lo tanto, con un bajo consumo per capita. Se requeriría educar al consumidor chino sobre la palta (madurez, preparación, calidad, entre otros). Perú debería aprovechar de mostrar su calidad al tener autorización fitosanitaria.

Además de que tiene una “ventana” donde puede entrar como proveedor como se muestra en el gráfico 16, prácticamente no tiene un competidor como proveedor de palta. En el gráfico 17 se muestra más a detalle qué mes es donde Perú exporta. Si bien no se tomará como país para analizar más adelante, era necesario detallar sobre su comportamiento por la importancia que representa en el estudio de mercados potenciales. No se tomará debido a que la pandemia ha tenido un impacto en sus importaciones de palta, es posible al no ser tan conocido y al ocurrir una pandemia, tuvo un impacto grande en la canasta familiar excluyéndolo como un producto no necesario.

Por otro lado, Estados Unidos y Países Bajos no tuvieron un impacto en sus importaciones, al igual que la disminución de las importaciones en China se explicarían por la popularidad

de la palta en el país; asimismo, explica por qué no han disminuido en los países mencionados. Al contrario, han subido, en Estados Unidos según lo mencionado en




Gráfico 18: Importaciones mensuales de China de los países más representativos

AgroNegocios, es debido porque las personas en Estados Unidos se están preocupando más por su salud y que ya no solo se hace guacamole con la palta sino también ensaladas, burritos y tostadas de aguacates.

Se ve que en el rango de mayo a agosto se ve que es donde se exporta y se ve un crecimiento notorio los últimos años. Para tener una idea más clara de la importancia de China como mercado potencial se tomó un gráfico del BBVA Research, se decidió solo hablar de China porque es el mercado potencial más importante, más que Turquía e India, que igual son mercados potenciales.




Figura 27: Posición relativa de los países en contraste con los otros

Fuente: BBVA Research (2019)

## 4.2.2 Estados Unidos

Estados Unidos tiene un gran potencial de consumo por su población y el consumo per cápita que tiene. Según un estudio de la *Hass Avocado World* en 2019, el 50% de hogares americanos no consumen palta, hay una potencial capacidad de duplicar su volumen. Además, menciona lo siguiente “Queda mucho trabajo por hacer para que aumente el volumen y sostenga precios”. Por otro lado, el consumo de Estados Unidos ha aumentado notoriamente, en el 2003 consumía 1.05 kilos y ahora en el 2020 consumo 3.71. En el siguiente gráfico se mostrará a los principales proveedores de palta de EE. UU., que representan más del 95% de su mercado, y su comportamiento en los años. Asimismo, se verá la posibilidad del Perú para entrar como un fuerte proveedor.




Gráfico 19: Importaciones mensuales de Estados Unidos de los países más representativos

Se puede visualizar que Perú y México son los principales proveedores de Estados Unidos, y también se ve una clara ventana que cuando en México se disminuye la importación por la estacionalidad de la palta, justo Perú está en el tiempo preciso para proporcionar lo que necesita. Es importante que Perú pueda prever cuándo México disminuya su producción para cosechar antes y poder exportar en el tiempo adecuado. Sin embargo, no se ve bien qué meses son los que el Perú debería poner más atención. En el siguiente gráfico se podrá visualizar

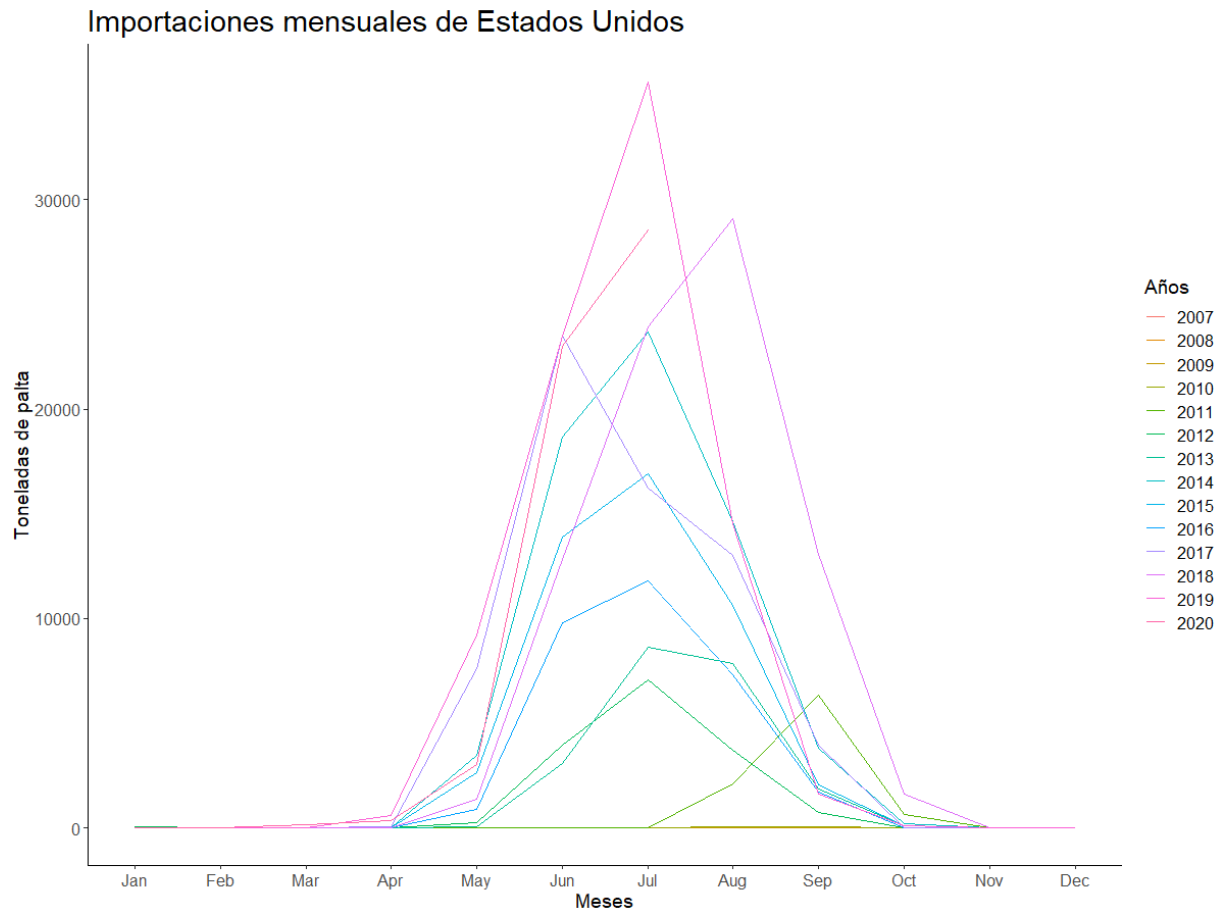


Gráfico 20: Importaciones mensuales de Estados Unidos de los países más representativos  
 El rango de importaciones más alto de Perú para Estados Unidos sería de junio a agosto. Hay que tomar en cuenta que Estados Unidos lo toma como importación cuando llega.

#### 4.2.3 Países Bajos

Países Bajos es el principal importador de Perú con la palta, al igual que con Estados Unidos se mostrará los posibles meses donde haya una “ventana” donde el Perú pueda aprovechar las estacionalidades de los otros países. Es sumamente importante determinar qué meses son los que el Perú exporta mayor cantidad de toneladas y si Perú tiene competidores como proveedor a Países Bajos en esos meses.




Gráfico 21: Importaciones de Países Bajos de los países más representativos

Primero se mostrará las importaciones de Países Bajos y sus principales importadores que ocupan más del 80% de su mercado. En el siguiente gráfico se podrá visualizar el comportamiento en el tiempo de las importaciones de Países Bajos.

Se ve que Perú es el principal exportador de Países Bajos y que compite con Kenya y Sudáfrica en la estacionalidad, si bien no son competidores fuertes con Países Bajos, es bueno tener el panorama claro. En el gráfico 21 se muestra los meses donde Perú exporta a Países Bajos un mayor volumen de palta. Se puede visualizar que este año hubo un incremento claro a pesar de la pandemia, eso demuestra que se toma como producto no intercambiable a pesar de la crisis, se podría decir que forma parte de la canasta para los que viven allí.

Se ve el comportamiento de todo el año, pero los meses donde se muestra mayor volumen importada es en abril, mayo y junio. Si bien este año en julio del 2020 se vio el incremento más alto, es solo un año y la tendencia de los años anteriores muestra el intervalo de meses previamente mencionados. Es importante tener en cuenta que el tiempo de cosecha para la palta es máximo de 3 meses, es debido a eso que solo se puede escoger un intervalo de meses de máximo 3 meses.






Gráfico 22: Importaciones mensuales de Países Bajos de los países más representativos

### 4.3 Mercado disponible en Estados Unidos y Países Bajos

Como se ha mostrado previamente, los países más representativos para las exportaciones peruanas y que tienen un crecimiento mayor al mercado son Estados Unidos y Países Bajos. Para ambos países se pronosticará de enero del 2021 hasta diciembre de 2021 y se hará una diferencia con el año 2020 para saber cuánto sería el estimado a la demanda de los dos países.

#### 4.3.1 Mercado disponible de Estados Unidos

El mercado que se plantea será hasta el fin del 2021, se ha realizado esto por medio de las herramientas ARIMA y Holt Winters evaluando cuál era mejor en cada caso, en el caso de ARIMA también evaluando los supuestos requeridos. Para más detalle se puede ver el Anexo 21 donde está el código con el que se realizó el análisis. Además, se mostrará a continuación el comportamiento de los países y el comportamiento acumulado de todo para ver cómo se comporta en general las importaciones de Estados Unidos con el mundo, que en este caso sería representado por los países en mención

Importaciones de Estados Unidos con la proyección




Gráfico 23: Importaciones históricas y proyectadas de Estados Unidos de los países más representativos

El valor numérico a donde apuntaría el Perú sería el contraste con el año 2020, se ha proyectado de agosto a diciembre del 2020 porque en el tiempo de realización de la investigación se tenía hasta ese punto, se tomará como supuesto que los valores proyectados sean los reales.

Tabla 27: Importación del 2020 de Perú a EE.UU. y su proyección al 2021

Meses	EEUU/Peru 2020	EEUU/Peru 2021	Diferencia
Enero	0	13	13
Febrero	0	9	9
Marzo	161	72	-89
Abril	352	340	-12
Mayo	3,041	6,031	2,990
Junio	22,979	27,052	4,073
Julio	28,551	35,184	6,633
Agosto	22,994	25,464	2,470
Setiembre	7,643	8,457	814
Octubre	682	754	72
Noviembre	2	2	0
Diciembre	5	5	0

### 4.3.2 Mercado disponible de Países Bajos

En el caso de Países Bajos, no tenemos una competencia para buscar el principal importador. Se debe analizar la demanda del país para planear cuánto se podrá exportar. Los países representativos son los siguiente: Chile, Sudáfrica, Kenya, Perú y México.

A continuación, se muestra el gráfico de los principales importadores y el acumulado al cual se le dará el nombre de “Mundo”.




Gráfico 24: Importaciones históricas y proyectadas de Países Bajos de los países más representativos

Como se mencionó al inicio y se puede corroborar, Perú tiene una gran participación en el mercado de Países Bajos y prácticamente direcciona cómo será el comportamiento de sus importaciones. A partir de los pronósticos realizados, se tiene al igual que en el caso de Estados Unidos, un proyectado al 2021 y se realizará la diferencia con el 2020 con el mismo supuesto de la proyección para completar el 2020.

Tabla 28: Importación del 2020 de Perú a Países Bajos. y su proyección al 2021

Meses	Países Bajos/Peru 2020	Países Bajos/Peru 2021	Diferencia
Enero	811	735	-76
Febrero	1,136	1,392	256
Marzo	5,421	4,201	-1,220
Abril	15,258	18,797	3,539
Mayo	23,845	36,203	12,358
Junio	35,258	30,253	-5,005
Julio	20,492	20,079	-413
Agosto	19,775	22,025	2,250
Setiembre	11,723	13,045	1,322
Octubre	3,075	3,418	343
Noviembre	327	364	37
Diciembre	239	266	27

#### 4.3.3 Mercado disponible total

Desde el punto de vista del Perú se debe tener un total para saber cuánto debería producir cada mes por la demanda insatisfecha que se genera al restar ambos años. Acerca de eso, se realizó la siguiente tabla para tener el valor final de la suma de las diferencias de Países Bajos y Estados Unidos.

Tabla 29: Total del mercado disponible

Meses	Total
Enero	-63
Febrero	265
Marzo	-1309
Abril	3527
Mayo	15348
Junio	-932
Julio	6220
Agosto	4720
Setiembre	2136
Octubre	415
Noviembre	37
Diciembre	27

Se ve que hay exceso en unos meses, para no desperdiciar ese “extra” de producción que existe se movería un mes adelante para que no afecte al proceso mismo y se pueda aprovechar la producción a realizar. Debido a esto, se optará por pasarlo un mes adelante y sumar el valor, como se muestra en la tabla 30.

Tabla 30: Valor para exportar por mes modificados

Meses	Previo	Moviendo un mes adelante la exportación
Enero	-63	0
Febrero	265	202
Marzo	-1309	0
Abril	3527	2218
Mayo	15348	15348
Junio	-932	0
Julio	6220	5288
Agosto	4720	4720
Setiembre	2136	2136
Octubre	415	415
Noviembre	37	37
Diciembre	27	27

Sin embargo, no se enfocará en este estudio todos los meses, solo los de la ventana mencionada previamente, de abril hasta agosto. En la tabla 31 se mostrará los valores por mes realizando el mencionado filtro.

Tabla 31: Valor de exportación por mes para el modelo

Meses	Ventana
Enero	0
Febrero	0
Marzo	0
Abril	2218
Mayo	15348
Junio	0
Julio	5288
Agosto	4720
Setiembre	0
Octubre	0
Noviembre	0
Diciembre	0

## 4.4 Modelo matemático propuesto

Se han escogido la informalidad y pobreza como indicadores sociales, y el rendimiento como indicador de la capacidad actual del terreno. Por otro lado, se busca maximizar la eficiencia e impacto para proponer dónde y cuándo se debería cosechar qué cantidad según los recursos de agua y terreno comentados anteriormente.

### 4.4.1 Supuestos

Los supuestos definirán el alcance del problema y definirá el problema más específicamente. A continuación, se mostrarán los supuestos.

- El universo del mercado va a ser los países seleccionados.
- Los supuestos realizados sobre la pobreza, informalidad, agua y terreno disponible aplican para el modelo.
- Los rendimientos promedios de los años son representativos para los distritos.
- Se hará una iterativa con el flujo de caja para sacar el rendimiento mínimo aceptable.

#### 4.4.2 Parámetros del modelo

Son los datos recolectados y analizados para utilizarlos en el modelo matemático propuesto. Se encuentran en el Anexo 3 y 4, y en los puntos 3.5, 3.6 y 3.7 del informe.

- $rend_j$  : Los rendimientos por distrito y mes obtenidos
- $pobj$  : Los índices de pobreza por distrito obtenidos del INEI
- $inf_j$  : Los índices de informalidad por distrito obtenidos del INEI
- $a_{ij}$  : El índice agua disponible por distrito mensual
- $agua_{ij}$  : El agua disponible por distrito mensualmente
- $t_j$  : El terreno disponible por distrito
- $mesdisp_{ij}$  : Meses hábiles para producir por distrito
- $vent_j$  : Máximo de producción por mes
- $z$  : Consumo de agua ( $hm^3$ ) por hectárea
- $minhect$  : Mínima cantidad de hectáreas para que sea viable el proyecto
- $minexp$  : Mínima cantidad para exportar por mes para que sea rentable

#### 4.4.3 Variables de decisión

Son los datos que serán recogidos luego de la optimización del modelo propuesto, que vendrían a ser las variables. A continuación, se muestran.

- $produ\_cant_{ij}$  : Producción en toneladas por distrito y mes
- $produ\_bin_{ij}$  : Activador de producción por distrito y por mes
- $prod\_anual_j$  : Activador de producción en el año de un distrito

#### 4.4.4 Índices

Son las letras pequeñas al costado de los datos de entrada y de salida.

- $i$  = meses, 1..12
- $j$  = distritos, 1..37

#### 4.4.5 Modelo matemático

##### Función objetivo

Busca maximizar el rendimiento, se haya escogido los distritos con mayor informalidad y pobreza, y realizar la mayor producción posible por mes y distrito. Se normalizará a cada uno restando su media respectiva y dividirlo entre su desviación estándar; finalmente se multiplicaría con el peso que se le dará a cada uno.

$$MAX \sum_{j=1}^J \sum_{i=1}^I \left( \left( \frac{(100 - a_{ij}) - (100 - 73.22)}{18.82} + \frac{rend_i - 11.33}{4.54} * 3 + \frac{(inf_i - 88.63)}{4.46} * 2 + \frac{(pob_i - 28.33)}{18.82} * 4 \right) * produ\_bin_{ij} + produ\_cant_{ij} \right)$$

##### Restricciones

Las restricciones implican la limitación de recursos o puntos que se deben cumplir para que represente al problema en la vida real.

**El agua mensual máxima que se puede consumir por distrito**

$$produ\_bin_{ij} * produ\_cant_{ij} * \frac{1}{rend_j} Z \leq agua_{ij} \quad \forall i \text{ en meses}, \forall j \text{ en in distritos}$$

**El terreno máximo que se puede utilizar por distrito**

$$\sum_{i=1}^I produ\_bin_{ij} * produ\_cant_{ij} * \frac{1}{rend_j} \leq t_j \quad \forall j \text{ en distritos}$$

**La producción máxima que se puede tener en función de la “ventana” comercial**

$$\sum_{j=1}^J produ\_bin_{ij} * produ\_cant_{ij} \leq vent_i \quad \forall i \text{ en meses}$$

**La mínima cantidad de hectáreas a cosechar para que sea rentable.**

$$\sum_{i=1}^I produ\_bin_{ij} * produ\_cant_{ij} * \frac{1}{rend_j} \geq minhect * prod\_anual_j \quad \forall j \text{ en in distritos}$$

**Para que solo produzca en los meses disponible de cosecha de los distritos**

$$produ\_bin_{ij} \leq mesdisp_{ij} \quad \forall i \text{ en meses}, \forall j \text{ en in distritos}$$

**Si no se activa el binario mensual no se produzca**

$$produ\_cant_{ij} \leq produ\_bin_{ij} * produ\_cant_{ij} \quad \forall i \text{ en meses}, \forall j \text{ en in distritos}$$

#### Mínima cantidad mensual para exportar

$$produ\_cant_{ij} * produ\_bin_{ij} \geq produ\_bin_{ij} * minexp \quad \forall i \text{ en meses}, \forall j \text{ en in distritos}$$

Permite que se active el binario mensual solo si se activa el anual, si se activa el anual permite que hayan hasta 3 meses activos.

$$\sum_{i=1}^I produ\_bin_{ij} \leq prod\_anual_j * 3 \quad \forall j \text{ en in distritos}$$

## 4.4 Modelo matemático propuesto en AMPL

Los datos que se utilizan en el modelo se mostrarán en el anexo 3, como se ha comentado en el marco teórico, se utilizará AMPL GUROBI para resolver este modelo de optimización mixto. A continuación, se colocará el código.

```
#set
set meses:= 1..12;
set distritos:=1..37;
#Matriz
set matriz1:={meses,distritos};

#####
##### Variables #####
#####

#produ_bin activador de producción por distrito y por mes
#produ_cant cantidad de producción por mes y distrito
#prod_anual activador de producción en el año de un distrito

var produ_bin {matriz1} binary ;
var produ_cant {matriz1} integer >=0;
var prod_anual {distritos} binary ;

#Parámetros rend=rendimiento, pob=pobreza, inf=informalidad por distrito, t=terreno
disponible por distrito, ai=índice de agua disponible por distrito
,vent=máximo de producción por mes, z=consumo de agua de la palta por hectárea
(hm^3)

param rend {distritos};
param pob {distritos};
```



```

param inf {distritos};
param ai {distritos};

param agua {matriz1};
param t {distritos};
param vent {meses};
param z := 0.0125;
param mesdisp {matriz1};
param minhect := 30;
param minexp := 50;

#####
##### Función objetivo #####
#####
# Se han normalizado los valores de la función objetivo y el 10000 es para que también
tenga un peso grande la parte de asignación
maximize asignacion:
sum {(i,j) in matriz1} (((100-ai[j])-26.78)/18.82+(rend[j]-11,33)*3/4.54+(pob[j]-
28.33)*4/18.82+(inf[j]-84.63)*2/4.46)*produ_bin[i,j]+produ_cant[i,j]);

#####
##### Restricciones #####
#####

# Solo producir en el mes disponible
subject to mensual_disponible{(i,j) in matriz1}:
produ_bin[i,j]<=mesdisp[i,j];

#Se activa el binario anual solo si un mensual es activado
subject to mensual_anual{j in distritos}:
sum{i in meses} produ_bin[i,j]<=prod_anual[j]*3;
#Si no se asigna no genere producción
subject to lower{(i,j) in matriz1}:
produ_cant[i,j]<=produ_bin[i,j]*produ_cant[i,j];

# Agua mensual máxima por distrito ##
subject to agua_max{(i,j) in matriz1}:
produ_bin[i,j]*produ_cant[i,j]*1/rend[j]*z<=agua[i,j];

# Terreno máximo por distrito
subject to terreno_max{j in distritos}:
sum{i in meses} produ_bin[i,j]*produ_cant[i,j]*1/rend[j]<=t[j];

# Producción máxima por mes
subject to produ_max{i in meses}:
sum{j in distritos} produ_bin[i,j]*produ_cant[i,j]<=vent[i];

```

```
# Mínima cantidad de hectareas anuales para que sea rentable
subject to hect_min_anual{j in distritos}:
sum{i in meses} produ_bin[i,j]*produ_cant[i,j]*1/rend[j]>=30*prod_anual[j];

# Mínima cantidad mensual a exportar
subject to hect_min_mes{(i,j) in matriz1}:
produ_bin[i,j]*produ_cant[i,j]*1/rend[j]>=50*produ_bin[i,j];
```



## CAPITULO 5: ANÁLISIS FINANCIERO

### 5.1 Costos para implementación de una hectárea

Se busca hallar el monto de la inversión para una hectárea de palta, según Guillermo Parodi (2014) responsable del Programa Nacional de Innovación e Industria de Palta Hass y otros Negocios Frutícolas de Sierra Exportadora; menciona que se requieren S/ 15,000 anuales por hectárea. Además, comenta que con un precio de S/ 2.6 por kilogramo con un rendimiento de 20 toneladas por hectárea, se puede llegar a un ingreso de S/ 52,000 y con un margen de S/ 37,000 anual. Si bien el rendimiento es relativo dependiendo del lugar, se puede tener un panorama.

Según una tesis realizada en Lambayeque llamada “ESTUDIO DE PRE - FACTIBILIDAD PARA LA PRODUCCION DE PALTA HASS (Persea americana Mill)” EN LA REGIÓN LAMBAYEQUE CON FINES DE EXPORTACIÓN” se comenta que 10 hectáreas estarían 65,000 dólares; en el caso fuera 1 hectárea y en soles sería 26,000 soles con un tipo de cambio de 4.00. Se estaría tomando ese monto para cuantificar el costo y generalizarlo para la inversión del terreno.

### 5.2 Costo de oportunidad

Se tienen los costos anuales y el detalle en los anexos de un caso para poder tener un panorama de cómo serían los costos; se trabajarán con esos datos. Sin embargo, antes de plantear un ingreso por hectárea promedio, debido a que cada distrito tiene rendimiento de terreno diferente; se hallará el costo de oportunidad que vendría a ser el CAPM. A partir del CAPM se sabría el rendimiento mínimo necesario para que sea viable, esto ya estaría contemplado en el modelo matemático, pero se desarrollará la explicación en este punto. A continuación, se muestra la fórmula del CAPM.

$$CAPM = R_f + \beta * (R_m - R_f) + R_p$$

$R_f$ =Rentabilidad esperada del activo sin riesgo

$R_m$ = Rentabilidad del mercado

$R_p$ = Riesgo país

$\beta$ = Beta apalancado del activo

Si bien Damodaran brinda un beta desapalancado, se optará tomar el valor investigado por medio de una tesis para maestría llamada “COSTO DE OPORTUNIDAD DEL SECTOR AGRÍCOLA COMERCIAL EXPORTADOR EN EL PERÚ: 1998-2017” que se enfocó en el

costo de oportunidad del sector agrícola. Halló que el beta apalancado es 1.25, estudiando desde el año 1998 al 2017 el comportamiento en la Bolsa de Valores. Se debe desapalancar el beta para poder aplicarlo en la estructura de capital que se planea tener. El beta que se ha hallado sería el de las empresas grandes, pero en este caso sería para empresarios pequeños.



Gráfico 25: Indicador de apalancamiento financiero para empresas con ventas netas mayores a 300 UIT

Fuente: Camasi, C (2019)

En el gráfico se muestra el indicador de las empresas extraído del IV Censo Nacional Económico 2008 no muestra el área agrícola, pero sabiendo el contexto del país y la necesidad económica de las actividades. Se tomará el indicador de sector de pesca y de acuicultura para el indicador para los agricultores grandes y de esta manera.

Para poder desapalancar el beta otorgado por la tesis, que es 1.25 y el impuesto a la renta de tercera categoría será de 15% en el sector agrícola según la SUNAT, esos se colocarán en la fórmula a continuación.

$$\beta_E = \beta_U [1 + (1 - t) * \frac{D}{C}]$$

$\beta_U$  = Beta desapalancado

$\beta_E$  = Beta apalancado

$t$  = Tasa de impuestos

$\frac{D}{C}$  = Relación deuda capital

A continuación, se calculará el beta desapalancado

$$\beta_U = \frac{1.25}{[1 + (1 - 0.15) * 2.03]}$$

$$\beta_U = 0.50$$

Ya teniendo el beta desapalancado se debería apalancar al promedio de financiamiento que tienen los agricultores, según “Redefiniendo el financiamiento para la agricultura: crédito agrícola verde para pequeños productores del Perú” realizado por *Unlockig forest Finance* y *Global canopy*, se menciona lo siguiente : “*Hemos debatido en otra publicación que para que los agricultores vean el crédito agrícola verde como un incentivo para hacer la transición hacia la sostenibilidad, necesitarían acceder a créditos que se puedan pagar en cuatro años, con tasas de interés cercanas a un dígito y preferencialmente con períodos de gracia 12. Estos requisitos se aplicarían a los créditos que financiaran el 70 % de los requisitos de capital del agricultor para una explotación agrícola promedio de seis hectáreas de producción de cacao, con requisitos similares para otros cultivos. En general, parece que los agricultores entrevistados tienen menos requisitos en términos de la diferencia entre capital de trabajo e inversión.*”. Si bien el estudio es del cacao, se puede generalizar porque la necesidad de capital es similar entre agricultores y el porcentaje al ser adimensional se puede tomar como un ratio. En términos de relación deuda/capital, el valor que saldría sería 2.33; realizando el proceso inverso para hallar el beta desapalancado, se buscará hallar el beta apalancado, pero para este negocio. El valor del beta apalancado sería 1.37. Ahora que se tiene el beta se deben hallar los otros componentes del CAPM.

La tasa libre de riesgo se halla promediando el rendimiento de los tres últimos años del bono de Estados Unidos con un plazo de 10 años según la BCRP. El valor resultante es 1.92%, se muestra a continuación el histórica para que se pueda ver cómo ha sido su comportamiento.

Gráfico 26: Rendimiento del bono EE. UU con plazo de 10 años (últimos 3 años)



Investigando el histórico del riesgo país en el BCR se realizó la gráfica siguiente y viendo su comportamiento se tomará el promedio desde el enero del 2018 hasta febrero de 2021 quitando los meses de marzo hasta junio del 2020 ya que muestran un comportamiento atípico que es contextual a ese periodo. El valor calculado es 1.39%, el cual se tomará como riesgo país para calcular el CAPM.




Gráfico 27: Riesgo país de Perú desde el periodo de agosto de 2006 hasta febrero 2021

El rendimiento del mercado será el hallado en la tesis para maestría “COSTO DE OPORTUNIDAD DEL SECTOR AGRÍCOLA COMERCIAL EXPORTADOR EN EL PERÚ: 1998-2017” el cual según el promedio de los últimos 20 años saca un valor de 22.58%.

Con los valores ya obtenidos haciendo el cálculo con la fórmula del CAPM sería la siguiente operación

$$CAPM = 0.0192 - 1.37 * (0.2258 - 0.0139) + 0.0139$$

$$CAPM = 0.3234$$

El CAPM sería igual como el costo de oportunidad en este caso, así que el COK es 32.34%.

### 5.3 Costo promedio ponderado de capital

Ya obtenido el valor del COK, se buscará hallar el CPPC o WACC por sus siglas en ingles. El valor final sería el rendimiento que debería tener como mínimo para que sea rentable los proyectos.

La fórmula para hallar el valor es la siguiente.

$$WACC = [D / I \times TIR \times (1 - T)] + [C / I \times COK]$$

- D/I: Ratio deuda-inversión total del proyecto
- TIR: Tasa interna de retorno
- T: Tasa efectivo de impuesto
- C/I: Ratio capital – inversión total del proyecto
- COK: Costo de oportunidad de capital soles

Tomando como referencia las tasas de interés del sistema bancario, se optará por el banco BBVA ya que el menor TEA para préstamos de cuota fija mayor a 360 días a microempresas, se clasifica ahí porque el proyecto generaría menos de 150 UIT. El valor que otorga es de 10.90%, en este caso sería el TIR.

Reemplazando los valores se realizará el cálculo.

$$WACC = [0.7 \times 0.1090 \times (1 - 0.15)] + (0.3 \times 0.3234)$$

$$WACC = 0.1619$$

Ahora que se tiene el WACC, se creará un caso promedio para saber cuánto ganaría un agricultor como mínimo, con el rendimiento menor usado en el proyecto y con una cantidad de 5 hectáreas. Se tomará como punto de partida la tesis “ESTUDIO DE PRE - FACTIBILIDAD PARA LA PRODUCCION DE PALTA HASS (Persea americana Mill) EN LA REGIÓN LAMBAYEQUE CON FINES DE EXPORTACIÓN” haciéndole las modificaciones necesarias para que pueda tomarse este caso como un caso genérico.

## 5.4 Flujo de caja

Bajo lo analizado previamente, como se ha comentado se partirá de la tesis “ESTUDIO DE PRE - FACTIBILIDAD PARA LA PRODUCCION DE PALTA HASS (Persea americana Mill) EN LA REGIÓN LAMBAYEQUE CON FINES DE EXPORTACIÓN”. Tener en cuenta que hay un supuesto en esta tesis y es que se consigue agua por medio de agua subterránea, ese es un supuesto nuevo que se utilizará para realizar el flujo de caja.

Se ha tomado un rendimiento promedio de 10 toneladas anuales por hectárea debido a que es el rendimiento mínimo dentro de los lugares seleccionados por el modelo. Se han realizado modificaciones a la tesis debido a que toma 10 hectáreas como terreno de cultivo y un rendimiento de 17 toneladas anuales por hectárea. Además, en rango de los precios bajo una entrevista con un profesional en el rubro agrícola con conocimientos en la exportación de palta Hass. Se muestran a continuación el precio de compra por kilo con un intermediario y sin intermediario, se tomará el promedio como precio para hallar el flujo de ingreso.

Tabla 32: Tabla de precios de la palta Hass por kilo

Tabla de precios		
Precios/Kg	Con intermediario	Sin intermediario
Pmin	5	6
Pmax	6	7.5
Precio Promedio	5.5	6.75

El flujo de kilos por año se colocará en el anexo 10. Por otro lado, el flujo se realizado para 18 años debido a la teoría de proyectos finitos, la cual dice que idealmente se debe tomar toda la vida del proyecto, pero si el proyecto tiene una cantidad de años que no se ve viable seguir proyectando debido al factor de error o que el proyecto no tiene un tiempo de vida definida, se tomaría 10 años. Sin embargo, en este caso el tiempo del proyecto se define por el tiempo de vida de la planta y su producción como la venta no habría motivo para que varíen, ya que como se ha visto actualmente post-pandemia, la venta de la palta no ha decaído y hasta ha aumentado.

Los flujos se colocarían en los anexos por tema de tamaño de gráfico; por otro lado, acerca del flujo que se han realizado en dos partes, por medio del flujo económico (anexo 11,12 y 13) y el flujo financiero neto (anexo 17,18 y19), para que con la suma de sus resultados anuales se pueda llegar al flujo financiero, que muestra la liquidez anual del proyecto.

Además, en la parte baja del flujo económico, se muestra el flujo acumulado, por el cual se halló el monto necesario para el proyecto y con la proporción deuda/capital hallada previamente, se halló el monto de cada uno. Se muestra a continuación una parte del flujo económico y el flujo acumulado para que se pueda tener un panorama. Como se ve, se requirió S/ 36,189.58 por hectárea.

Tabla 33: Panorama de flujo económico

Descripción	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5
Kilos cosechados	-	-	250.61	1,169.53	2,297.30	4,176.90
<b>Ingreso</b>						
Io						
Monto en soles exportación (90%)	-	-	1,522.48	7,104.91	13,956.07	25,374.67
Monto en soles Perú (10%)	-	-	137.84	643.24	1,263.51	2,297.30
Total de ingresos	-	-	1,660.32	7,748.15	15,219.58	27,671.96
<b>Egresos</b>						
Terreno	26,000.00	-	-	-	-	-
<b>Costos Directos</b>						
Semillas e injertos (Var. Hass)	1,785.00	-	-	-	-	-
Agua	171.00	138.00	152.00	184.00	212.00	309.00
Mano de obra	520.00	618.00	679.00	641.00	738.00	1,000.00
Insumo agrícolas (cultivo)	1,161.00	1,372.00	1,509.00	1,834.00	2,109.00	2,404.00
Mano de obra (cosecha)	-	-	15.00	73.00	147.00	166.00
<b>Costos indirectos</b>						
Cargas diversas de gestión	452.00	505.00	539.00	984.00	9,595.00	1,303.00
Combustible	227.00	2,687.00	295.00	295.00	246.00	334.00
Servicios prestados por terceros	107.00	127.00	140.00	137.00	100.00	136.00
Combustible (cosecha)	-	-	-	24.00	49.00	61.00
Transporte a punto de encuentro	-	-	200.00	400.00	500.00	500.00
Servicios de transporte a Lima	-	-	162.90	760.20	1,493.24	2,714.99
Servicio de maquila	-	-	593.00	276.00	543.00	988.00
Total de egresos	30,423.00	5,447.00	4,284.90	5,608.20	15,732.24	9,915.99
Impuesto a la renta (IR)	-	-	-	320.99	-	2,663.40
<b>Flujo económico</b>	<b>- 30,423.00</b>	<b>- 5,447.00</b>	<b>- 2,624.58</b>	<b>1,818.96</b>	<b>- 512.66</b>	<b>15,092.58</b>
<b>Flujo acumulado</b>	<b>- 30,423.00</b>	<b>- 35,870.00</b>	<b>- 38,494.58</b>	<b>- 36,354.63</b>	<b>- 36,867.29</b>	<b>- 19,111.31</b>



Como se ve en la tabla, sería necesario acotar, que se tomó bajo una entrevista con alguien conocedor del sector, que el 90% de lo cosechado iría para la venta del exterior, pero no toda la fruta es de la calidad necesaria; el 10% restante se vendería en mercado nacional. Se podría plantear que sea a nivel distrital.

## 5.5 Indicadores financieros

Los indicadores financieros que se utilizaron fueron el Valor Actual Neto Económico (VANE), Valor Actual Neto Financiero (VANF), TIR para ambos flujos (económico y financiero) y el periodo de recuperación en el flujo económico; se hallaron para un estado pesimista, probable y optimista.

Primero se mostraría los VANE y VANF en cada escenario, haciendo aumentar o disminuir un 5% de los ingresos anuales para tener un intervalo adecuado para el análisis. Primero se muestra usando como tasa el WACC.

Tabla 34: VAN(WACC)

VAN (WACC)		
Escenario	VANE	VANF
<b>Pesimista</b>	S/84,822.03	S/89,081.20
<b>Probable</b>	S/93,054.40	S/97,305.30
<b>Optimista</b>	S/100,717.55	S/104,960.18

Ya mostrado el VANE y VANF con la tasa WACC; se usará el COK, para realizar una evaluación más exigente. Esta solo tomaría el rendimiento deseado por el cliente, es mayor al WACC debido a que el WACC se compensa a la tasa que pide el banco. Por lo tanto, la tasa al ser mayor el VANE y VANF serán menores pero positivos.

Tabla 35: VAN(COK)

VAN (COK)		
Escenario	VANE	VANF
<b>Pesimista</b>	S/2,630.72	S/10,942.06
<b>Probable</b>	S/4,887.93	S/13,183.14
<b>Optimista</b>	S/6,971.97	S/15,251.04

Luego de ver el VAN en estos casos se ve su rentabilidad en todos los casos. A continuación, se mostrará el TIR para poder contrastarlo con el WACC y COK. Para tenerlo a la mano, el WACC es de 16.19% y el COK de 32.34%.

Tabla 36: TIR

<b>TIR</b>		
<b>Escenario</b>	<b>TIR E.</b>	<b>TIR F.</b>
<b>Pesimista</b>	33.76%	41.38%
<b>Probable</b>	34.91%	42.99%
<b>Optimista</b>	35.94%	44.43%

Como se ve, en los dos flujos también cumplen que el TIR en cada caso es mayor tanto al WACC y al COK, que es un indicador más estricto que el WACC. Entonces también se podría decir que es rentable.

Acerca del periodo de recuperación, sería de 6 años. Se podrá ver visualmente en las tablas de flujos que estarán en los anexos previamente mencionados.



## CAPÍTULO 6: ANÁLISIS DE RESULTADOS

Habiendo corrido el programa y por medio del análisis con herramientas de *analytics*, se analizarán para poder brindar información relevante acerca del tema de estudio

### 6.1 Análisis descriptivo

En el gráfico 13 se muestra la posición en función de las características climáticas de cada distrito a estudiar y con una graduación de color en función del rendimiento de cada uno. Los distritos de la misma zona geográfica deberían estar ubicados cercanos y en teoría deberían tener un rendimiento similar ya que en el sentido climático se parecen, y teniendo como supuesto que el terreno tiene las mismas cualidades y no está deteriorado. Se visualiza que en la esquina superior izquierda están agrupados los de la selva, en la esquina superior derecha los de la costa y por la parte central baja los de la sierra.

Un punto muy interesante en la sierra es un punto rojo que es el distrito de Ayacucho que está en la provincia de Huamanga y departamento de Ayacucho tiene un alto rendimiento a pesar de tener símiles alrededor del mismo. Esto lleva a unas preguntas, ¿Estás cuidando muy bien el terreno y plantas? o ¿están descuidando mucho a los que están su alrededor en el gráfico?

Sin importar la respuesta, indica un potencial de incremento de rendimiento sobre los terrenos cercanos de Ayacucho, Huánuco, entre otros. Se puede ver en el gráfico 15 los que están agrupados con el distrito de Ayacucho, de color rojo claro. Esto muestra que es posible que tenga un gran potencial de rendimiento los distritos que en el diagrama de PCA están Cerca a Ayacucho. Se recomendaría tener en cuenta para posibles futuros análisis de la tierra las siguientes zonas: Ayacucho-Carmen Alto, Ayacucho-Huanta, Ayacucho-Pacaycasa y Huánuco-Jacas Grande.

### 6.2 Resultados del modelo

Ya corrido el modelo usando el *solver* Gurobi, tuvieron como resultado la siguiente tabla. Se mostrará a continuación un fragmento de la tabla con las toneladas por mes-distrito debido al tamaño de las tablas; sin embargo, se colocarán en los anexos 7,8 y 9 todas las tablas completas, las tablas de la variable cantidad y las dos de variables binarias que sirvieron de activador mensual y anual.

Tabla 37: Cantidad de toneladas por distrito-mes

Cantidad de toneladas a producir por distrito					
DISTRITOS	Abril	Mayo	Junio	Julio	Agosto
Amazonas,Bagua,La Peca	-	8,898	-	-	-
Ayacucho,Huamanga,Carmen Alto	-	550	-	-	-
Ayacucho,Huamanga,Pacaycasa	-	550	-	-	-
Ayacucho,Lucanas,Chaviña	618	550	-	-	-
Ayacucho,Huanta,Huanta	-	500	-	-	-
Cajamarca,Cajabamba,Cachachi	1,050	-	-	-	-
Cajamarca,Cajabamba,Cajabamba	-	-	-	4,638	4,220
Cuzco,Paruro,Accha	-	750	-	-	-
Cuzco,Paruro,Ccapi	-	750	-	-	-
Huancavelica,Castrovirreyna,Arma	-	750	-	-	-
Huancavelica,Churcampa,Churcampa	-	650	-	650	-
Huancavelica,Tayacaja,Colcabamba	550	550	-	-	-
Huánuco,Huamalies,Jacas Grande	-	-	-	-	500
Pasco,Oxampampa,Oxapampa	-	850	-	-	-

Como se puede ver en la tabla, muestra el lugar nivel Departamento-Provincia-Distrito, el cual sería el lugar donde se propone exportar palta hass. Por otro lado, los números que aparecen en la tabla son las toneladas que se propone exporta según el mes donde muestra la columna. Esto se basa en los índices ya previamente explicados en el modelo y buscando optimizar el impacto de la agricultura en la población y buscando su rentabilidad.

En los anexos 7 y 8 se muestran las variables binarias que sirvieron para el modelo y en el anexo 9 la tabla completa con todos los distritos y meses.

### 6.3 Análisis del flujo de caja

Viendo los indicadores en el punto 5.4, se puede ver que el proyecto de una hectárea es rentable con los supuestos mencionados previamente. Esto permite una gran oportunidad a los pequeños agricultores que no tienen mucho dinero para comprar 10 o más hectáreas para recién ahí llegar a entrar al mercado. Si bien el proyecto es rentable, la metodología que se anda proponiendo no es para solo una persona sino para poder brindar una solución a grupos que lo necesitan y así mejorar los indicadores usados en el modelo de optimización.

Además, el análisis por escenario permite una tranquilidad al inversionista-agricultor de que no tiene que ser exactamente esa cantidad para que sea rentable y que el rendimiento tomado es uno bajo con respecto al promedio al igual que un costo de transporte alto, así que este caso analizado abarcaría todos los casos en general para poder asegurar la rentabilidad de los proyectos. Adicionalmente, tiene el supuesto que va a haber una entidad externa organizadora y que permita el contacto con comercio exterior, la cual se detallará en las recomendaciones del estudio.

Por otro lado, se hizo un análisis para saber cuál es el precio del producto para que no sea rentable en cada escenario: pesimista, probable y optimista. Para el flujo pesimistas S/ 5.34, para el probable S/ 5.03 y para el optimista S/ 4.74, serían los puntos de equilibrio.

## **CAPÍTULO 7: CONCLUSIONES**

Después del exhaustivo análisis sobre la viabilidad de promover la plantación de la palta Hass en las provincias tomando en cuenta indicadores socio-económicos en el modelo matemático que se corrió en AMPL. Se llegó a un monto por medio de la teoría de series de tiempo para incentivar cuánto debería exportarse este año, en qué meses y qué países.

Además, se analizó la viabilidad económica de una hectárea en el flujo de caja con el mínimo rendimiento de terreno de la provincias provistas para el análisis en el modelo y costos de transportes desde el lugar más lejano de se tuvo como output de AMPL se puede asegurar la viabilidad que el flujo muestra para todos los distritos. Adicionalmente, se evaluó escenarios pesimista y optimistas para abarcar un Intervalo de confianza razonable.

### **7.1 Conclusiones**

A continuación, se presentarán las conclusiones.

- Hay distritos que tienen gran potencial según el análisis realizado con la teoría de los principales componentes. El factor clima y altura es similar, lo que indica que es posible que el terreno con el tratamiento adecuado puede aumentar el rendimiento de la tierra.
- La herramienta de principales componentes permite ver un posible potencial oculto que normalmente no se podría detectar debido a que solo se ven los valores finales, en este caso el rendimiento, pero no las variables que pueden hacer al terreno uno con un alto rendimiento.
- No todos los agricultores tienen acceso para poder invertir en una gran cantidad de hectáreas para poder acceder al mercado exterior o no tengo el contacto. Debido a eso vende a un precio más bajo por medio de un intermediario. Con el contacto, control de calidad y la correcta organización se puede acceder al mercado exterior y vender a un mayor precio.
- El uso de las series de tiempo para poder pronosticar por el momento sirve para organizar a los exportadores, con más factores que complementarían el análisis se podría tener un panorama de no solo 1 año sino más años para pronosticar y poder determinar cuántas hectáreas se recomendarían sembrar en el año 0. Si bien el

proyecto es de más de 10 años, el enfoque del mismo es que se logre orquestar a los múltiples agricultores en diferentes sectores para que puedan exportar y mejorar las oportunidades de éxito que tendrían, recordar que la propuesta tiene un enfoque macro.

- El estudio no solo abarca a la palta Hass, se puede aplicar la metodología desarrollada para cualquier producto agrícola que tiene una estacionalidad para poder buscar una ventana comercial potencial donde el Perú pueda aumentar sus exportaciones.
- Al realizar el flujo de caja, se pudo validar si es rentable una hectárea con el supuesto de que se agruparían los agricultores para exportar como conjunto. Para esto se requiere de una entidad como Sierra Exportadora para dar una mano en la organización, control de calidad y contactos con el exterior.
- Después de evaluar el análisis de sensibilidad, en el cual se evaluó cuánto se cosecharía cada mes, se pudo llegar a la conclusión que es rentable en todos los casos. Lo cual permite tener un intervalo de seguridad en el tema de cuánto se debería cosechar.

## 7.2 Recomendaciones

A continuación, se plantearán las recomendaciones.

- Sería necesario que la entidad Sierra Exportadora que tiene como rol según la página del gobierno del Perú lo siguiente: “Impulsamos la actividad económica de las zonas rurales de la sierra y selva de nuestro país para lograr el acceso de los pequeños y medianos productores organizados a los mercados de manera sostenible y competitiva, contribuyendo a la reducción de la pobreza.”, actúe como organizador entre los agricultores para organizar grupos de agricultores para que la capacidad de producción sea mayor y cada uno tenga acceso a un mayor precio de venta. Para que esto sea posible, también se es necesario que actúe como contacto ante el exterior para conseguir clientes y pueda actuar como intermediario entre agricultor-cliente. Además, que pueda crear un control de calidad para asegurar al cliente del exterior que la palta Hass que se está enviando sea de calidad.
- Realizar estudios similares con otras frutas o verduras que tengan un impacto socio-económico alto y que tengan un potencial de exportación viable para comenzar a promoverlo. Esto se recomendaría realizar bajo un diagrama de Pareto, para organizarse de una manera adecuada e invertir en lo óptimo.

- Realizar estudio con diagramas de principales componentes para analizar potenciales terrenos para la agricultura por cultivo, con conocer los climas de cada distrito, sería iterativo contrastando el rendimiento del lugar.
- Dar a conocer a los agricultores que colectivamente se puede llegar a mejores oportunidades de ventas.



## BIBLIOGRAFÍA

- Agraria. (18 de Julio de 2016). Obtenido de <https://agraria.pe/noticias/huanuco-cacao-y-derivados-representan-el-11588>
- Agraria. (10 de Enero de 2018). Obtenido de <https://agraria.pe/noticias/siembran-236-plantones-de-palta-hass-en-la-provincia-de-boli-15672>
- Agrícola, R. (Agosto de 2017). Obtenido de <https://www.redagricola.com/pe/la-palta-de-los-andes-compite-sola-en-los-mercados/>
- Agrícola, R. (Mayo de 2020). Obtenido de <https://www.redagricola.com/pe/las-claves-peru-se-posicione-segundo-productor-paltas-mundo/>
- Andina. (13 de Marzo de 2014). *Andina*. Obtenido de <https://andina.pe/agencia/noticia-sierra-exportadora-proyecta-exportaciones-palta-215-millones-497780.aspx>
- Andina. (13 de Marzo de 2014). *Andina*. Obtenido de <https://andina.pe/agencia/noticia-sierra-exportadora-proyecta-exportaciones-palta-215-millones-497780.aspx>
- Andina. (Marzo de 2021). Obtenido de <https://andina.pe/agencia/noticia-huancavelica-productores-del-vraem-exportan-90-toneladas-palta-hass-a-europa-y-asia-839332.aspx>
- Barría, C. (7 de Agosto de 2019). *BBC News*. Obtenido de <https://www.bbc.com/mundo/noticias-49209380>
- BCRP. (s.f.). *¿Cual es el retorno mínimo exigido para invertir en una entidad financiera peruana?* Lima.
- BCRP. (2021). *TASA DE INTERÉS PROMEDIO DEL SISTEMA BANCARIO*. Obtenido de <https://www.sbs.gob.pe/app/pp/EstadisticasSAEEPPortal/Paginas/TIActivaTipoCreditoEmpresa.aspx?tip=B>
- Chain, N. S. (s.f.). *PROYECTOS DE INVERSIÓN Formulación y Evaluación*. En N. S. Chain. Pearson.
- Correo. (18 de Febrero de 2018). Obtenido de <https://diariocorreo.pe/peru/huanuco-eexportaciones-de-cafe-y-minerales-caen-433-803812/>
- Damodaran, A. (Enero de 2021). *Stern*. Obtenido de [http://pages.stern.nyu.edu/~adamodar/New\\_Home\\_Page/datafile/Betas.html](http://pages.stern.nyu.edu/~adamodar/New_Home_Page/datafile/Betas.html)



- Económica, A. (03 de Diciembre de 2020). *Alerta Económica*. Obtenido de <https://alertaeconomica.com/consumo-per-capita-de-palta-en-europa-aun-tiene-potencial-de-crecimiento/>
- El Peruano*. (08 de Noviembre de 2020). Obtenido de <https://elperuano.pe/noticia/107730-fertilizantes-sin-igv-benefician-a-productores>
- Feliciano, J. (2014). *IMPULSO A LA PALTA HASS EN EL ANDE*. Obtenido de <http://www.sierraexportadora.gob.pe/>
- FreshPlaza. (20 de Abril de 2018). *Portal del Campo*. Obtenido de [https://portaldelcampo.cl/Noticias/66509\\_Estrategias-para-disminuir-el-consumo-de-agua-en-palto.html](https://portaldelcampo.cl/Noticias/66509_Estrategias-para-disminuir-el-consumo-de-agua-en-palto.html)
- Frisku Foods. (Octubre de 2018). *Red Agrícola*. Obtenido de <https://www.redagricola.com/cl/palta-crece-la-oferta-pero-crece-aun-mas-la-demanda/>
- Gestión. (08 de Mayo de 2016). Obtenido de <https://gestion.pe/economia/98-exportaciones-amazonas-cafe-podra-exportar-otros-productos-119953-noticia/>
- Hillier, L. (2001). *Investigación de operaciones*. México: Interamericana editores.
- La Cámara. (2019). *Perú, país minero y agropecuario*. Lima: Cámara de Comercio de Lima.
- MINAGRI. (05 de Noviembre de 2020). *Gobierno del Perú*. Obtenido de <https://www.gob.pe/institucion/midagri/noticias/312617-gobierno-exonera-el-100-del-igv-a-fertilizantes-para-impulsar-agricultura-familiar>
- MINAGRI. (s.f.). Seminario: Situación Actual del Sector Agrario Referente al cambio climático. Lima, Perú: MINAGRI.
- Nicole Bernex, K. Y. (s.f.). *Capítulo 3: Aprovechamiento del Agua*. Obtenido de <https://ciga.pucp.edu.pe/wp-content/uploads/2017/09/3.-CAPITULO-3.pdf>
- Perú, G. d. (s.f.). *Gobierno del Perú*. Obtenido de <https://www.gob.pe/sse>
- Peruano, E. (02 de Marzo de 2018). *El Peruano*. Obtenido de <https://elperuano.pe/noticia/64362-agro-genera-1-de-cada-4-empleos-formales-en-peru>
- Red agrícola. (Septiembre de 2019). *Red agrícola*. Obtenido de <https://www.redagricola.com/pe/palta-exitos-y-excesos/>

- ROJAS, W. E. (2016). *Repositorio Institucional Nacional Agraria La Molina*. Obtenido de <https://repositorio.lamolina.edu.pe/bitstream/handle/UNALM/2828/E71-N8-T.pdf?sequence=1&isAllowed=y>
- SENASA. (26 de Septiembre de 2016). Obtenido de <https://www.senasa.gob.pe/senasacontigo/pasco-senasa-monitorea-plagas-en-zona-de-produccion-de-paltas-hass-para-campana-de-exportacion-2017/>
- SENASA. (10 de Mayo de 2019). Obtenido de <https://www.senasa.gob.pe/senasacontigo/senasa-ayacucho-exporto-mas-de-5-mil-toneladas-de-palta-hass-a-china/>
- SENASA. (13 de Febrero de 2019). Obtenido de <https://www.senasa.gob.pe/senasacontigo/productores-de-apurimac-se-preparan-para-exportar-palta-hass-a-mercados-internacionales/>
- Sierra y Selva Exportadora, MINAGRI. (2020). *Análisis de mercado*. Lima.
- Spark, W. (s.f.). Obtenido de <https://es.weatherspark.com/countries/PE>
- SUNAT. (2019). *INFORME N.º 015-2019-SUNAT/7T0000*. LIMA.
- Travel Group Perú. (30 de Octubre de 2020). *Travel Group Perú*. Obtenido de Travel Group Perú: [http://www.travelgroup.com.pe/conoce-peru/informacion\\_general#:~:text=Per%C3%BA%20est%C3%A1%20ubicado%20en%20la,occidental%20de%20Am%C3%A9rica%20del%20Sur.&text=Tiene%20una%20superficie%20de%201285.215,grande%20en%20Am%C3%A9rica%20del%20Sur.](http://www.travelgroup.com.pe/conoce-peru/informacion_general#:~:text=Per%C3%BA%20est%C3%A1%20ubicado%20en%20la,occidental%20de%20Am%C3%A9rica%20del%20Sur.&text=Tiene%20una%20superficie%20de%201285.215,grande%20en%20Am%C3%A9rica%20del%20Sur.)
- Winston, W. L. (2005). *Investigación de operaciones*. México: Thomson.
- Zuta, D. A. (2019). *Las regiones geográficas del Perú, clasificación y teorías diversas*. Lima : Universidad Nacional de Educación.

# ANEXOS

## Anexo 1: Manual AMPL para comprensión de la tesis

### Programa de modelamiento matemático

Para la programación se usará “*A Mathematical Programming Language*” o AMPL por sus siglas en ingles. Como ya se mencionó antes es un programa que se enfoca en la optimización de las soluciones para problemas lineales, no lineales y cuadráticas convexas. Es el software más usado por los investigadores y, en este caso, se utilizará más adelante para poder modelar y dar una solución efectiva.

#### Interfaz del programa

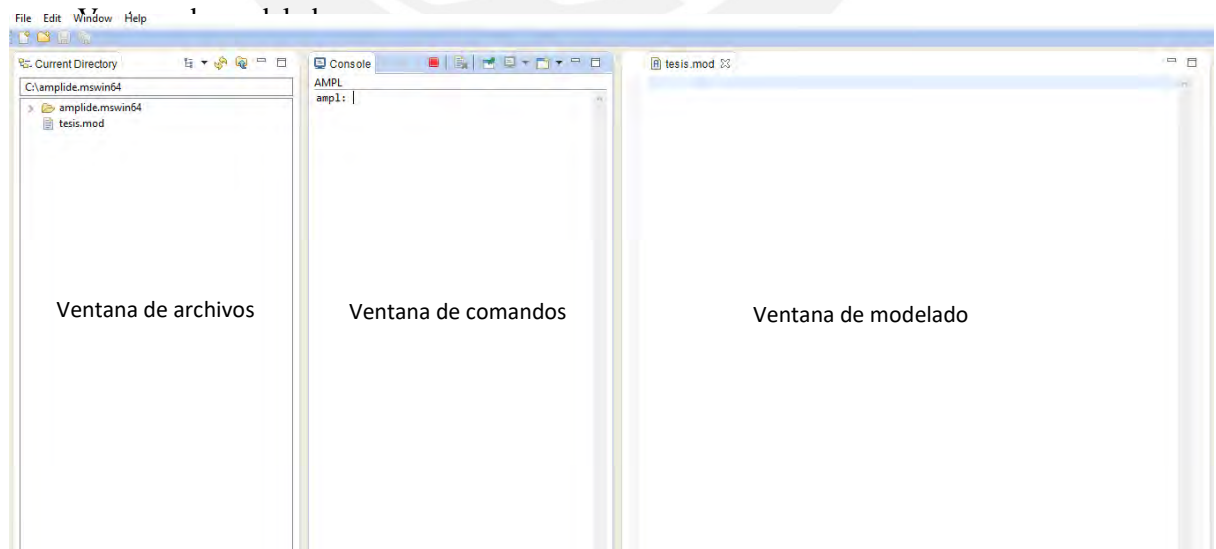
Es donde se encuentran 3 ventanas las cuales son las siguientes:

- Ventana de archivos

Su uso es para que se pueda navegar dentro de los documentos y poder hallar el documento necesario para poder abrirlo y utilizarlo. En la parte superior de la ventana se encuentra el botón de “nuevo documento”, “nuevo folder”, “guardar” y “guardar todos”, que se refiere a guardar a todas las ventas aun no estando seleccionadas.

- Ventana de comandos

Es poder ejecutar comandos para poder interactuar con el modelado planteado en la ventana de su derecha.



## Tipos de documentos

Existen 3 tipos de documentos en este programa: archivos “. mod”, “. dat”, “. run” y “. text”. El primero es para realizar el modelado con el lenguaje que AMPL tiene, el segundo es para colocar los parámetros que adoptará el modelo planteado, el tercero es para poder facilitar ciertas órdenes en el tipo de archivo “.mod” y el cuarto trabaja igual que un bloc de notas para cualquier anotación que sea necesaria y se desea anotar.

### Set

Es la creación de una columna no visible donde se colocarán los parámetros o variables de decisión que vienen a ser los datos, los cuales se explicarán más adelante a detalle. Estos sets pueden ser de dos maneras: lineales y matriciales. Pueden llamarse muchas veces desde parámetros o variables ya que son una guía cómo se acomodarán los datos. Sobre su sintaxis, en el caso de los sets de tipo lineal su nomenclatura es la siguiente:

```
set MatrizA := 1..40;
```

Significa que se ha creado un espacio de 40 datos de manera lineal, es la base para poder crear todo lo demás que se explicará más adelante. Sobre el set de tipo matricial su nomenclatura es la siguiente:

```
set set1:=1..20;  
set set2:= 1..40;  
set MatrizB:={set1,set2};
```

La matriz B es el ejemplo, donde está compuesta por 2 sets lineales donde tiene 20 filas y 40 columnas dicha matriz.

### Parámetros

Son los datos que se utilizarán como materia prima para llegar a la solución luego de haber planteado el modelo en la ventana de modelado. Estos deben llamar a un tipo de set para poder colocar los datos que se ingresan en “los espacios vacíos” que crean los sets. Su nomenclatura es la siguiente:

```
param parametro1{set2};  
param parametro2{MatrizB};
```

El primero está llamando a un set lineal y el segundo que aparece está llamando a un set matricial.

## Variables

Para colocar las variables de decisión se tienen que plantear a partir de un tipo de set; al igual que los sets pueden ser lineales o matriciales. A continuación, se mostrará su sintaxis.

```
var variable1 {set1};  
var variable2 {MatrizB};
```

Como se puede notar, cual sea su tipo de variable, lineal o matricial, su nomenclatura es la misma para llamar al set con el que se vinculará.

Para poder definir el tipo de variables se deben colocar ciertos comandos, para el caso de naturales mayor a 0 si no se coloca nada el programa asume que lo es. Sin embargo; a continuación, se presentarán los comandos necesarios para definir de manera adecuada a las variables.

```
var P1 {MatrizB} >=0;  
var P2 {MatrizB} integer;  
var P3 {MatrizB} binary;
```

Para el primer caso se muestra cómo se define un tipo de variable tipo natural mayor a 0; en el segundo caso, se muestra una variable definida como entera; y, en el último caso, se presenta la manera de definir una variable binaria. Se da a entender que es aquí donde se hace presente el rango de existencia de las variables de decisión.

## Función objetivo

Ya se ha explicado en el punto 1.2.2 sobre la función objetivo; sin embargo, en este punto se explicará su nomenclatura y cómo trasladar la idea matemática al plano de

programación. Primero se parte creando un modelo matemático. Por ejemplo, se planteará a continuación un modelo con una sola sumatoria.

$$\text{Maximizar } \sum^{20} (\text{Precio}[i] - \text{Costo}[i]) * \text{Cantidad\_Producto}[i]$$

El modelo previo desea optimizar la utilidad, escogiendo la mejor cantidad de producto “i”, “i” es el contador; por lo tanto, ahora se transformará del lenguaje matemático al lenguaje de AMPL.

```

maximize Utilidades:
sum{i in set1} (Precio[i]-Costo[i])*Cantidad_Producto[i];

```

En la formulación *maximize* significa que se opta por maximizar el valor de la sumatoria que tiene como comando “sum”. Si se deseara minimizar se pondría *minimize*; a continuación, se colocará si no fuera solamente una suma lineal, sino que fuese a partir de una matriz. A continuación, se empleará un ejemplo para que se comprenda el análisis. Se tenía que decidir por una óptima puntuación televisiva y se tenían los datos de puntajes por medio de comunicación dependiendo del horario que se suelen dar cada uno y la variable “x” es la variable la cantidad de anuncios contratados en el horario “i” por el medio “j”, no se colocarán las restricciones para una mejor comprensión.

$$\sum_{j=1}^{40} \sum_{i=1}^{20} x[i, j] * \text{puntaje}[i, j]$$

Ya planteado el modelo matemático, corresponde transformarlo al lenguaje AMPL.

```

maximize puntajetotal:
sum {(i,j) in MatrizB} x[i,j]*puntaje[i,j];

```

En este caso, se usó un set matricial para poder dar forma a la sumatoria porque la variable “x” depende de dos factores: horario y tipo de medio. En este caso la variable “x” es entera por lo tanto se tendría que haber definido como *integer*.

## Restricciones

Al igual que el anterior punto, ya se ha hablado sobre este tema en el punto 1.2.2, en esta parte de la tesis se explicará cómo se transformará del lenguaje matemático a el lenguaje utilizado en este programa que se hace mención. Para comenzar se mostrará el modelo matemático para la restricción de costos que puede tener la empresa en gastos de marketing por vía de medios.

$$\text{Costo}[i, j] * x[i, j] \leq 500\ 000$$

Expresa lo previamente mostrado que el costo total no puede sobrepasar el valor de 500 000 soles, la inversión realizada en el proyecto será en soles. A continuación, la transformación al lenguaje requerido.

```
subject to Costo:  
sum{(i,j) in cuadro} costos[i,j]*x[i,j]<= 500000;
```

Para comenzar la restricción se coloca el comando “subject to” y luego se coloca el nombre de la restricción; en este caso, es solamente una restricción, más adelante se mostrará luego cuando se desean colocar varias restricciones a la vez. El “sum” es para llamar a una sumatoria como se ha mencionado ya previamente.

Ahora se mostrará un ejemplo modificado del anterior en donde se tienen varias restricciones para el gasto por tipo de medio. A continuación, el modelo matemático.

$$\text{Costo}[i, j] * x[i, j] \leq \text{Costo\_límite}[j]$$

Como se mencionó antes, el contador “i” será para los horarios y el contador “j” es para los tipos de medios. Debido a ese motivo el límite del costo por medio se moverá en el contador “j”.

```
subject to Costo {j in set2}:  
sum {i in set1} costos[i,j]*x[i,j]<= Costo_limite[j];
```

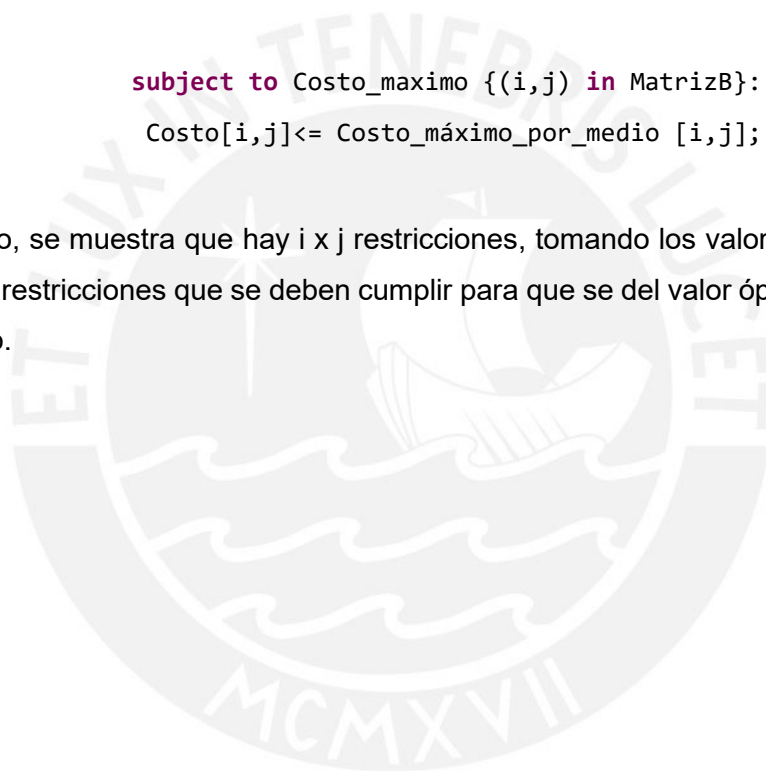
En este caso se tendrá la misma cantidad de restricciones que la cantidad que se estructuró el "set2". Por cada tipo de medio se tendrá un costo límite como restricción para invertir en el. Aún hay un caso más que se puede detallar cuando se forma las restricciones a partir de un set matricial.

$$\text{Costo}[i, j] \leq \text{Costo\_m\u00e1ximo\_por\_medio}[i, j]$$

Se plantea que hay un costo m\u00e1ximo por cada horario vinculado con un medio de comunicaci\u00f3n. Por ejemplo, que para el horario de 9 am a 10 am solo se puede gastar 1000 soles por medio televisivo. Asimismo, se traducir\u00e1 al lenguaje requerido para la optimizaci\u00f3n.

```
subject to Costo_maximo {(i,j) in MatrizB}:  
    Costo[i,j]<= Costo_m\u00e1ximo_por_medio [i,j];
```

En este ejemplo, se muestra que hay  $i \times j$  restricciones, tomando los valores ser\u00edan 20x40 que ser\u00edan 800 restricciones que se deben cumplir para que se del valor \u00f3ptimo que dar\u00e1 la funci\u00f3n objetivo.





## Anexo 2: Tabla input para el análisis PCA

La temperatura está en Celsius, precipitación en mm, altura en metros, viento en kilómetros por hora, energía solar en kWh, proporción de nubes en porcentaje y rendimiento en toneladas por hectárea.

Departamento	Mes	Provincia	Distrito	Temperatura_media	Temperatura_min	Temperatura_max	Precipitacion	Altura	Viento	Energia_solar	Proporcion_de_nubes	Rendimiento
Amazonas	Enero	Bagua	Bagua	28.1	22.7	33.5	40	430	10.00	5.60	80	7
Amazonas	Febrero	Bagua	Bagua	28.55	23	34.1	58	430	10.00	5.60	82	7
Amazonas	Marzo	Bagua	Bagua	28.25	22.5	34	63	430	10.00	5.60	80	7
Amazonas	Abril	Bagua	Bagua	27.50	22.00	33.00	40.00	430.00	10.00	5.60	75.00	7
Amazonas	Mayo	Bagua	Bagua	26.50	21.00	32.00	13.00	430.00	10.00	5.40	56.00	7
Amazonas	Junio	Bagua	Bagua	26.25	20.50	32.00	7.00	430.00	11.00	5.60	52.00	7
Amazonas	Julio	Bagua	Bagua	26.00	20.00	32.00	3.00	430.00	12.00	5.70	34.00	7
Amazonas	Agosto	Bagua	Bagua	27	21	33	5	430	13.40	5.90	29	7
Amazonas	Septiembre	Bagua	Bagua	27.75	21.5	34	13	430	11.40	6.30	50	7
Amazonas	Octubre	Bagua	Bagua	28.1	22	34.2	34	430	10.00	5.80	60	7
Amazonas	Noviembre	Bagua	Bagua	28	22	34	34	430	8.70	5.60	70	7
Amazonas	Diciembre	Bagua	Bagua	28	22	34	36	430	9.00	5.60	70	7
Amazonas	Enero	Rodriguez_de_Mendoza	Cochamal	20.00	15.00	25.00	57.00	1647.00	8.00	5.40	86.00	10
Amazonas	Febrero	Rodriguez_de_Mendoza	Cochamal	19.50	15.00	24.00	60.00	1647.00	8.00	4.90	90.00	10
Amazonas	Marzo	Rodriguez_de_Mendoza	Cochamal	19.00	14.00	24.00	65.00	1647.00	8.00	5.00	88.00	10
Amazonas	Abril	Rodriguez_de_Mendoza	Cochamal	18.5	14	23	55	1647	8.40	5.20	75	10
Amazonas	Mayo	Rodriguez_de_Mendoza	Cochamal	18.4	13.8	23	25	1647	8.60	5.20	57	10
Amazonas	Junio	Rodriguez_de_Mendoza	Cochamal	18	13	23	16	1647	9.50	5.40	50	10
Amazonas	Julio	Rodriguez_de_Mendoza	Cochamal	17.5	12	23	10	1647	10.30	5.60	42	10

Amazonas	Agosto	Rodriguez_de_Men donza	Cochamal	18.5	13	24	7	1647	10.40	6.00	44	10
Amazonas	Septiem bre	Rodriguez_de_Men donza	Cochamal	19.5	14	25	20	1647	10.00	6.00	57	10
Amazonas	Octubre	Rodriguez_de_Men donza	Cochamal	19.5	14	25	48	1647	8.50	5.70	72	10
Amazonas	Noviem bre	Rodriguez_de_Men donza	Cochamal	20	15	25	50	1647	8.00	5.50	80	10
Amazonas	Diciemb re	Rodriguez_de_Men donza	Cochamal	20	15	25	47	1647	8.20	5.50	82	10
Amazonas	Enero	Bagua	La_Peca	25.25	20	30.5	40	897	9.50	5.50	76	13
Amazonas	Febrero	Bagua	La_Peca	25.00	20.00	30.00	60.00	897.00	9.40	5.30	83.00	13
Amazonas	Marzo	Bagua	La_Peca	25.00	20.00	30.00	62.00	897.00	9.20	5.30	80.00	13
Amazonas	Abril	Bagua	La_Peca	25.00	20.00	30.00	48.00	897.00	9.50	5.20	65.00	13
Amazonas	Mayo	Bagua	La_Peca	25.00	20.00	30.00	16.00	897.00	11.00	5.20	52.00	13
Amazonas	Junio	Bagua	La_Peca	24.5	19	30	7	897	12.00	5.45	40	13
Amazonas	Julio	Bagua	La_Peca	24.25	18	30.5	4	897	12.80	5.80	33	13
Amazonas	Agosto	Bagua	La_Peca	24.95	18.9	31	6	897	13.00	6.10	35	13
Amazonas	Septiem bre	Bagua	La_Peca	25.75	19.5	32	15	897	12.00	6.20	47	13
Amazonas	Octubre	Bagua	La_Peca	25.5	20	31	30	897	10.00	5.70	65	13
Amazonas	Noviem bre	Bagua	La_Peca	25.4	20	30.8	36	897	9.00	5.60	73	13
Amazonas	Diciemb re	Bagua	La_Peca	25.25	20	30.5	38	897	9.40	5.50	75	13
Áncash	Enero	Casma	Casma	23.15	20.00	26.30	14.00	49.00	10.50	6.80	77.00	9
Áncash	Febrero	Casma	Casma	24.20	21.00	27.40	16.00	49.00	9.80	6.60	78.00	9
Áncash	Marzo	Casma	Casma	24.65	22.00	27.30	18.00	49.00	9.80	6.50	78.00	9
Áncash	Abril	Casma	Casma	23.20	21.00	25.40	12.00	49.00	10.00	6.30	53.00	9
Áncash	Mayo	Casma	Casma	22.5	20	25	5	49	11.30	6.20	50	9
Áncash	Junio	Casma	Casma	22	19	25	0	49	11.80	5.90	50	9
Áncash	Julio	Casma	Casma	21.5	18	25	0	49	11.80	6.30	32	9
Áncash	Agosto	Casma	Casma	21.5	18	25	0	49	12.40	6.70	30	9
Áncash	Septiem bre	Casma	Casma	21.5	18	25	3	49	12.20	7.10	36	9
Áncash	Octubre	Casma	Casma	21.75	18.5	25	9	49	11.50	7.00	53	9

Áncash	Noviembre	Casma	Casma	22	19	25	7	49	11.10	6.90	60	9
Áncash	Diciembre	Casma	Casma	22.5	20	25	15	49	10.80	6.80	62	9
Áncash	Enero	Santa	Chimbote	21.00	19.00	23.00	5.00	9.00	11.50	6.50	70.00	17
Áncash	Febrero	Santa	Chimbote	22.00	20.00	24.00	6.00	9.00	10.90	6.30	77.00	17
Áncash	Marzo	Santa	Chimbote	21.65	19.50	23.80	7.00	9.00	11.50	6.00	75.00	17
Áncash	Abril	Santa	Chimbote	20.15	18.50	21.80	4.80	9.00	12.00	6.10	50.00	17
Áncash	Mayo	Santa	Chimbote	19.25	17.50	21.00	2.00	9.00	13.10	5.90	38.00	17
Áncash	Junio	Santa	Chimbote	17.90	16.30	19.50	0.00	9.00	14.40	5.80	35.00	17
Áncash	Julio	Santa	Chimbote	17.15	15.50	18.80	0.00	9.00	15.00	6.00	30.00	17
Áncash	Agosto	Santa	Chimbote	16.65	15.30	18.00	0.00	9.00	15.30	6.50	29.00	17
Áncash	Septiembre	Santa	Chimbote	16.90	15.00	18.80	2.00	9.00	14.50	6.90	38.00	17
Áncash	Octubre	Santa	Chimbote	17.25	15.50	19.00	4.50	9.00	13.10	6.90	52.00	17
Áncash	Noviembre	Santa	Chimbote	18.15	16.80	19.50	3.00	9.00	12.70	6.90	57.00	17
Áncash	Diciembre	Santa	Chimbote	20.25	18.50	22.00	6.00	9.00	12.00	6.70	66.00	17
Apurímac	Enero	Abancay	Curahuasi	16.5	11	22	102	2879	7.00	5.20	93	6
Apurímac	Febrero	Abancay	Curahuasi	16.25	11.00	21.50	102.00	2879.00	6.80	5.30	93.00	6
Apurímac	Marzo	Abancay	Curahuasi	16.50	11.00	22.00	70.00	2879.00	6.50	5.30	89.90	6
Apurímac	Abril	Abancay	Curahuasi	16.15	10.00	22.30	25.00	2879.00	6.20	5.00	80.00	6
Apurímac	Mayo	Abancay	Curahuasi	14.65	7.00	22.30	5.00	2879.00	6.30	5.00	63.00	6
Apurímac	Junio	Abancay	Curahuasi	13.6	5.2	22	4	2879	6.40	5.10	58	6
Apurímac	Julio	Abancay	Curahuasi	13.7	5.2	22.2	4	2879	7.40	5.40	47	6
Apurímac	Agosto	Abancay	Curahuasi	15.1	7.2	23	7	2879	8.20	5.80	55	6
Apurímac	Septiembre	Abancay	Curahuasi	15.7	8.4	23	13	2879	8.60	5.70	69	6
Apurímac	Octubre	Abancay	Curahuasi	17.25	11	23.5	28	2879	8.00	5.60	85	6
Apurímac	Noviembre	Abancay	Curahuasi	17.45	11.2	23.7	50	2879	7.60	5.50	88	6
Apurímac	Diciembre	Abancay	Curahuasi	17	11.5	22.5	75	2879	7.30	5.23	90	6
Apurímac	Enero	Graú	Curpahuasi	12.00	6.00	18.00	95.00	3496.00	7.80	6.10	89.00	5

Apurímac	Febrero	Grau	Curpahuasi	12.00	6.00	18.00	90.00	3496.00	7.60	6.00	89.00	5
Apurímac	Marzo	Grau	Curpahuasi	11.75	5.50	18.00	63.00	3496.00	7.00	5.80	87.50	5
Apurímac	Abril	Grau	Curpahuasi	11.40	4.80	18.00	20.00	3496.00	6.90	5.50	75.00	5
Apurímac	Mayo	Grau	Curpahuasi	10.25	2	18.5	4	3496	7.00	5.40	56	5
Apurímac	Junio	Grau	Curpahuasi	8.85	-0.3	18	2	3496	7.80	5.30	50	5
Apurímac	Julio	Grau	Curpahuasi	8.5	-1	18	2	3496	8.00	5.70	40	5
Apurímac	Agosto	Grau	Curpahuasi	9.75	1	18.5	3	3496	8.50	6.00	45	5
Apurímac	Septiembre	Grau	Curpahuasi	10.75	2.5	19	13	3496	9.10	6.20	64	5
Apurímac	Octubre	Grau	Curpahuasi	12.25	5	19.5	25	3496	8.50	6.30	77	5
Apurímac	Noviembre	Grau	Curpahuasi	13	6	20	50	3496	8.00	6.40	82	5
Apurímac	Diciembre	Grau	Curpahuasi	12.3	6.3	18.3	75	3496	8.00	6.20	87	5
Apurímac	Enero	Andahuaylas	Huayana	14.15	8.00	20.30	57.00	3207.00	8.50	6.20	85.00	4
Apurímac	Febrero	Andahuaylas	Huayana	14.00	8.00	20.00	62.00	3207.00	8.50	6.20	87.00	4
Apurímac	Marzo	Andahuaylas	Huayana	14.00	8.00	20.00	40.00	3207.00	8.20	5.90	85.00	4
Apurímac	Abril	Andahuaylas	Huayana	13.90	8.00	19.80	13.00	3207.00	8.10	5.60	72.00	4
Apurímac	Mayo	Andahuaylas	Huayana	13.5	7.5	19.5	5	3207	8.00	5.40	56	4
Apurímac	Junio	Andahuaylas	Huayana	13.15	6.8	19.5	2	3207	8.70	5.30	53	4
Apurímac	Julio	Andahuaylas	Huayana	12.75	6	19.5	2	3207	9.40	5.50	45	4
Apurímac	Agosto	Andahuaylas	Huayana	13.5	7	20	4	3207	10.10	6.00	45	4
Apurímac	Septiembre	Andahuaylas	Huayana	14.25	7.5	21	11	3207	10.00	6.30	61	4
Apurímac	Octubre	Andahuaylas	Huayana	14.75	8	21.5	20	3207	9.30	6.45	76	4
Apurímac	Noviembre	Andahuaylas	Huayana	15	8	22	30	3207	8.30	6.60	79	4
Apurímac	Diciembre	Andahuaylas	Huayana	14.35	8	20.7	48	3207	8.30	6.30	83	4
Arequipa	Enero	Arequipa	Tiabaya	16.70	12.40	21.00	8.00	2176.00	10.80	7.20	75.00	8
Arequipa	Febrero	Arequipa	Tiabaya	16.60	12.70	20.50	12.00	2176.00	10.50	7.00	78.00	8
Arequipa	Marzo	Arequipa	Tiabaya	16.85	12.40	21.30	7.00	2176.00	10.00	6.80	70.00	8
Arequipa	Abril	Arequipa	Tiabaya	16.65	11.30	22.00	2.00	2176.00	9.40	6.40	53.00	8

Arequipa	Mayo	Arequipa	Tiabaya	16.35	10.4	22.3	0	2176	9.20	5.90	38	8
Arequipa	Junio	Arequipa	Tiabaya	15.75	9.3	22.2	0	2176	9.10	5.50	37	8
Arequipa	Julio	Arequipa	Tiabaya	15.5	9	22	0	2176	9.50	6.00	26	8
Arequipa	Agosto	Arequipa	Tiabaya	16.25	10	22.5	0	2176	10.00	6.50	30	8
Arequipa	Septiembre	Arequipa	Tiabaya	17	11	23	0	2176	10.40	7.40	35	8
Arequipa	Octubre	Arequipa	Tiabaya	17	11.5	22.5	0	2176	10.60	8.00	50	8
Arequipa	Noviembre	Arequipa	Tiabaya	17	12	22	2	2176	10.60	8.20	56	8
Arequipa	Diciembre	Arequipa	Tiabaya	16.65	12.3	21	8	2176	10.70	7.40	68	8
Arequipa	Enero	Arequipa	Uchumayo	17.50	13.00	22.00	10.00	1972.00	10.80	7.30	73.00	9
Arequipa	Febrero	Arequipa	Uchumayo	17.15	13.30	21.00	19.00	1972.00	10.50	7.00	77.00	9
Arequipa	Marzo	Arequipa	Uchumayo	17.50	13.00	22.00	10.00	1972.00	9.80	6.80	70.00	9
Arequipa	Abril	Arequipa	Uchumayo	17.25	12.00	22.50	3.00	1972.00	9.20	6.30	53.00	9
Arequipa	Mayo	Arequipa	Uchumayo	17	11	23	0	1972	9.00	6.00	39	9
Arequipa	Junio	Arequipa	Uchumayo	16.5	10.5	22.5	0	1972	8.90	5.50	36	9
Arequipa	Julio	Arequipa	Uchumayo	16	10	22	0	1972	9.30	5.80	26	9
Arequipa	Agosto	Arequipa	Uchumayo	16.5	10.5	22.5	1	1972	9.70	6.50	28	9
Arequipa	Septiembre	Arequipa	Uchumayo	17	11	23	0	1972	10.10	7.40	40	9
Arequipa	Octubre	Arequipa	Uchumayo	17	11.5	22.5	0	1972	10.30	7.80	52	9
Arequipa	Noviembre	Arequipa	Uchumayo	17	12	22	0	1972	10.80	8.20	56	9
Arequipa	Diciembre	Arequipa	Uchumayo	17.25	12.5	22	8	1972	10.80	7.50	68	9
Ayacucho	Enero	Huamanga	Ayacucho	15.15	10.10	20.20	67.00	2743.00	9.20	5.70	89.00	24
Ayacucho	Febrero	Huamanga	Ayacucho	14.95	9.80	20.10	78.00	2743.00	9.00	5.80	89.00	24
Ayacucho	Marzo	Huamanga	Ayacucho	14.80	9.50	20.10	54.00	2743.00	8.70	5.60	86.00	24
Ayacucho	Abril	Huamanga	Ayacucho	14.7	9.3	20.1	15	2743	8.50	5.50	74	24
Ayacucho	Mayo	Huamanga	Ayacucho	14.55	9	20.1	4	2743	8.20	5.20	60	24
Ayacucho	Junio	Huamanga	Ayacucho	14.25	8.5	20	3	2743	8.70	5.00	57	24
Ayacucho	Julio	Huamanga	Ayacucho	14	8	20	3.5	2743	9.20	5.40	49	24

Ayacucho	Agosto	Huamanga	Ayacucho	14.85	9	20.7	7	2743	10.00	5.80	52	24
Ayacucho	Septiembre	Huamanga	Ayacucho	15.9	9.8	22	15	2743	10.20	6.00	67	24
Ayacucho	Octubre	Huamanga	Ayacucho	16.1	10	22.2	24	2743	9.80	6.00	79	24
Ayacucho	Noviembre	Huamanga	Ayacucho	15.95	10.1	21.8	33	2743	9.40	6.10	81	24
Ayacucho	Diciembre	Huamanga	Ayacucho	15.60	10.20	21.00	50.50	2743.00	9.20	5.80	87.00	24
Ayacucho	Enero	Huamanga	Carmen Alto	14.5	9	20	65	2890	9.00	5.80	89	11
Ayacucho	Febrero	Huamanga	Carmen Alto	14.50	9.00	20.00	77.00	2890.00	8.80	5.80	89.00	11
Ayacucho	Marzo	Huamanga	Carmen Alto	14.50	9.00	20.00	50.00	2890.00	8.50	5.60	86.00	11
Ayacucho	Abril	Huamanga	Carmen Alto	14.25	8.50	20.00	15.00	2890.00	8.40	5.30	73.00	11
Ayacucho	Mayo	Huamanga	Carmen Alto	14.15	8.30	20.00	4.00	2890.00	8.20	5.20	59.00	11
Ayacucho	Junio	Huamanga	Carmen Alto	13.75	7.5	20	3	2890	8.50	5.10	57	11
Ayacucho	Julio	Huamanga	Carmen Alto	13.5	7	20	3	2890	9.20	5.40	48	11
Ayacucho	Agosto	Huamanga	Carmen Alto	14.15	7.8	20.5	6	2890	10.00	5.80	50	11
Ayacucho	Septiembre	Huamanga	Carmen Alto	14.85	8.8	20.9	14	2890	10.20	5.90	66	11
Ayacucho	Octubre	Huamanga	Carmen Alto	15.15	9	21.3	25	2890	9.70	6.00	79	11
Ayacucho	Noviembre	Huamanga	Carmen Alto	15.25	9.1	21.4	33	2890	9.30	6.60	82	11
Ayacucho	Diciembre	Huamanga	Carmen Alto	14.8	9.2	20.4	50	2890	9.00	5.80	88	11
Ayacucho	Enero	Lucanas	Chaviña	12.9	5.8	20	21	3224	10.00	6.90	73	11
Ayacucho	Febrero	Lucanas	Chaviña	12.9	5.8	20	21	3224	10.00	6.50	82	11
Ayacucho	Marzo	Lucanas	Chaviña	13.15	5.80	20.50	13.00	3224.00	9.80	6.30	76.00	11
Ayacucho	Abril	Lucanas	Chaviña	12.75	5.00	20.50	3.00	3224.00	10.00	6.10	55.00	11
Ayacucho	Mayo	Lucanas	Chaviña	12.00	4.00	20.00	1.00	3224.00	10.20	5.80	40.00	11
Ayacucho	Junio	Lucanas	Chaviña	11.00	3.00	19.00	1.00	3224.00	10.50	5.60	38.00	11
Ayacucho	Julio	Lucanas	Chaviña	10.5	2	19	1	3224	11.00	6.00	30	11
Ayacucho	Agosto	Lucanas	Chaviña	11.75	3.5	20	2	3224	11.00	6.50	29	11
Ayacucho	Septiembre	Lucanas	Chaviña	12.25	4	20.5	4	3224	11.40	7.10	40	11
Ayacucho	Octubre	Lucanas	Chaviña	13	5	21	7	3224	10.80	7.50	54	11

Ayacucho	Noviembre	Lucanas	Chaviña	13.4	5.5	21.3	13	3224	10.60	7.70	60	11
Ayacucho	Diciembre	Lucanas	Chaviña	13.4	6.3	20.5	18	3224	10.40	7.00	72	11
Ayacucho	Enero	Huanta	Huanta	16	11	21	55	2659	9.80	5.50	90	10
Ayacucho	Febrero	Huanta	Huanta	16.00	11.00	21.00	81.00	2659.00	9.40	5.50	90.00	10
Ayacucho	Marzo	Huanta	Huanta	16.00	11.00	21.00	60.00	2659.00	9.00	5.40	87.00	10
Ayacucho	Abril	Huanta	Huanta	16.00	11.00	21.00	13.00	2659.00	8.60	5.30	75.00	10
Ayacucho	Mayo	Huanta	Huanta	16.00	11.00	21.00	5.00	2659.00	8.40	4.90	60.00	10
Ayacucho	Junio	Huanta	Huanta	15.5	10	21	5	2659	8.70	5.00	58	10
Ayacucho	Julio	Huanta	Huanta	15	9	21	5	2659	9.30	5.30	50	10
Ayacucho	Agosto	Huanta	Huanta	15.5	10	21	7	2659	9.70	5.70	55	10
Ayacucho	Septiembre	Huanta	Huanta	16.5	11	22	10	2659	10.40	5.90	69	10
Ayacucho	Octubre	Huanta	Huanta	16.5	11	22	25	2659	10.00	5.90	80	10
Ayacucho	Noviembre	Huanta	Huanta	16.5	11	22	35	2659	9.70	5.90	81	10
Ayacucho	Diciembre	Huanta	Huanta	16	11	21	50	2659	9.40	5.70	86	10
Ayacucho	Enero	Huamanga	Pacaycasa	16	11	21	67	2563	9.40	5.60	89	11
Ayacucho	Febrero	Huamanga	Pacaycasa	15.5	11	20	80	2563	9.20	5.50	90	11
Ayacucho	Marzo	Huamanga	Pacaycasa	15.25	10.50	20.00	50.00	2563.00	9.00	5.40	87.00	11
Ayacucho	Abril	Huamanga	Pacaycasa	15.35	10.20	20.50	15.00	2563.00	8.60	5.20	75.00	11
Ayacucho	Mayo	Huamanga	Pacaycasa	15.40	9.80	21.00	5.00	2563.00	8.40	5.10	61.00	11
Ayacucho	Junio	Huamanga	Pacaycasa	15.00	9.00	21.00	3.00	2563.00	8.60	5.00	58.00	11
Ayacucho	Julio	Huamanga	Pacaycasa	14.5	8	21	4	2563	9.40	5.40	50	11
Ayacucho	Agosto	Huamanga	Pacaycasa	15.25	9	21.5	7	2563	10.00	5.80	53	11
Ayacucho	Septiembre	Huamanga	Pacaycasa	16	10	22	13	2563	10.40	5.90	67	11
Ayacucho	Octubre	Huamanga	Pacaycasa	16.5	10.5	22.5	25	2563	10.00	5.90	79	11
Ayacucho	Noviembre	Huamanga	Pacaycasa	16.5	11	22	33	2563	9.50	6.00	82	11
Ayacucho	Diciembre	Huamanga	Pacaycasa	16	11	21	56	2563	9.30	5.80	88	11
Cajamarca	Enero	Cajabamba	Cachachi	9.50	4.00	15.00	39.00	3550.00	6.20	5.70	83.00	21

Cajamarca	Febrero	Cajabamba	Cachachi	9.50	4.50	14.50	42.00	3550.00	6.00	5.30	90.00	21
Cajamarca	Marzo	Cajabamba	Cachachi	9.00	4.00	14.00	50.00	3550.00	5.80	5.10	88.00	21
Cajamarca	Abril	Cajabamba	Cachachi	8.35	3.00	13.70	38.00	3550.00	6.00	5.30	73.50	21
Cajamarca	Mayo	Cajabamba	Cachachi	7.7	2	13.4	15	3550	7.00	5.60	55	21
Cajamarca	Junio	Cajabamba	Cachachi	6.9	0.8	13	2.5	3550	8.80	5.80	45	21
Cajamarca	Julio	Cajabamba	Cachachi	6	0	12	1	3550	9.80	6.30	36	21
Cajamarca	Agosto	Cajabamba	Cachachi	7	1	13	2.5	3550	9.70	6.70	38	21
Cajamarca	Septiembre	Cajabamba	Cachachi	8.4	2.8	14	10	3550	8.00	6.50	55	21
Cajamarca	Octubre	Cajabamba	Cachachi	8	2	14	28	3550	6.80	6.10	71	21
Cajamarca	Noviembre	Cajabamba	Cachachi	8.45	2.9	14	25	3550	6.00	5.90	77	21
Cajamarca	Diciembre	Cajabamba	Cachachi	8.75	3.3	14.2	35	3550	6.30	5.80	81.5	21
Cajamarca	Enero	Cajabamba	Cajabamba	12	7	17	30	2636	7.20	5.70	85	19
Cajamarca	Febrero	Cajabamba	Cajabamba	11.5	7	16	40	2636	7.20	5.20	90	19
Cajamarca	Marzo	Cajabamba	Cajabamba	11.25	7	15.5	47	2636	7.30	5.10	89	19
Cajamarca	Abril	Cajabamba	Cajabamba	10.5	6	15	40	2636	7.40	5.20	78	19
Cajamarca	Mayo	Cajabamba	Cajabamba	10	5	15	13	2636	8.40	5.50	58	19
Cajamarca	Junio	Cajabamba	Cajabamba	9.00	4.00	14.00	5.00	2636.00	10.50	5.80	45.00	19
Cajamarca	Julio	Cajabamba	Cajabamba	9.00	4.00	14.00	2.00	2636.00	12.00	6.20	40.00	19
Cajamarca	Agosto	Cajabamba	Cajabamba	10.00	5.00	15.00	5.00	2636.00	12.10	6.70	40.00	19
Cajamarca	Septiembre	Cajabamba	Cajabamba	10.50	6.00	15.00	10.00	2636.00	10.30	6.30	63.00	19
Cajamarca	Octubre	Cajabamba	Cajabamba	11	6	16	30	2636	9.30	6.10	75	19
Cajamarca	Noviembre	Cajabamba	Cajabamba	11.25	6.5	16	32	2636	7.00	6.00	79	19
Cajamarca	Diciembre	Cajabamba	Cajabamba	11.25	6.5	16	32	2636	6.80	5.70	83	19
Cajamarca	Enero	Contumaza	San_Benito	18.50	14.00	23.00	25.00	1271.00	8.00	6.00	74.00	8
Cajamarca	Febrero	Contumaza	San_Benito	18.75	14.50	23.00	38.00	1271.00	7.50	5.65	83.00	8
Cajamarca	Marzo	Contumaza	San_Benito	18.75	14.50	23.00	32.00	1271.00	7.10	5.60	80.00	8
Cajamarca	Abril	Contumaza	San_Benito	18.25	14	22.5	25	1271	6.60	5.70	60	8



Cajamarca	Mayo	Contumaza	San_Benito	17.65	13	22.3	9	1271	6.20	5.75	45	8
Cajamarca	Junio	Contumaza	San_Benito	17.05	12	22.1	3	1271	6.30	5.85	35	8
Cajamarca	Julio	Contumaza	San_Benito	16.5	11	22	1	1271	6.40	6.30	27	8
Cajamarca	Agosto	Contumaza	San_Benito	17	12	22	3	1271	6.40	6.70	28	8
Cajamarca	Septiembre	Contumaza	San_Benito	17.25	12.5	22	5	1271	6.70	6.70	42	8
Cajamarca	Octubre	Contumaza	San_Benito	17.15	12.5	21.8	17.5	1271	7.10	6.50	60	8
Cajamarca	Noviembre	Contumaza	San_Benito	17.25	12.5	22	18	1271	7.85	6.50	63	8
Cajamarca	Diciembre	Contumaza	San_Benito	17.75	13.00	22.50	19.00	1271.00	7.90	6.20	70.00	8
Cuzco	Enero	Paruro	Accha	12	6	18	99	3580	7.30	5.80	92	15
Cuzco	Febrero	Paruro	Accha	12.00	6.00	18.00	80.00	3580.00	7.00	5.90	92.00	15
Cuzco	Marzo	Paruro	Accha	11.75	5.50	18.00	65.00	3580.00	6.50	5.80	89.00	15
Cuzco	Abril	Paruro	Accha	11.25	4.00	18.50	25.00	3580.00	6.70	5.40	75.00	15
Cuzco	Mayo	Paruro	Accha	10.50	2.00	19.00	3.00	3580.00	7.00	5.30	55.00	15
Cuzco	Junio	Paruro	Accha	9	-0.5	18.5	2	3580	7.60	5.40	48	15
Cuzco	Julio	Paruro	Accha	8.5	-1	18	2	3580	8.00	5.70	35	15
Cuzco	Agosto	Paruro	Accha	9.5	0.5	18.5	2	3580	8.50	6.10	45	15
Cuzco	Septiembre	Paruro	Accha	11	3.5	18.5	12	3580	9.10	6.10	63	15
Cuzco	Octubre	Paruro	Accha	11.75	4.5	19	27	3580	8.10	6.10	78	15
Cuzco	Noviembre	Paruro	Accha	12.75	5.5	20	48	3580	7.70	6.20	83	15
Cuzco	Diciembre	Paruro	Accha	12	6	18	80	3580	7.50	6.00	89	15
Cuzco	Enero	Paruro	Ccapi	14	8	20	102	3196	7.20	5.80	93	15
Cuzco	Febrero	Paruro	Ccapi	14.00	8.00	20.00	90.00	3196.00	7.00	5.80	92.00	15
Cuzco	Marzo	Paruro	Ccapi	14.00	8.00	20.00	70.00	3196.00	6.40	5.60	90.00	15
Cuzco	Abril	Paruro	Ccapi	13.25	6.00	20.50	15.00	3196.00	6.50	5.30	80.00	15
Cuzco	Mayo	Paruro	Ccapi	12.50	4.00	21.00	3.00	3196.00	6.80	5.20	60.00	15
Cuzco	Junio	Paruro	Ccapi	11.25	2	20.5	2	3196	7.50	5.20	50	15
Cuzco	Julio	Paruro	Ccapi	10.5	1	20	2	3196	8.00	5.50	40	15

Cuzco	Agosto	Paruro	Ccapi	11.5	2.5	20.5	2	3196	8.50	6.00	45	15
Cuzco	Septiembre	Paruro	Ccapi	13.75	6.5	21	15	3196	8.90	6.00	64	15
Cuzco	Octubre	Paruro	Ccapi	14.5	7.5	21.5	25	3196	8.00	6.00	80	15
Cuzco	Noviembre	Paruro	Ccapi	15	8	22	50	3196	7.70	6.00	85	15
Cuzco	Diciembre	Paruro	Ccapi	14	8	20	80	3196	7.50	5.80	90	15
Cuzco	Enero	La Convencion	Pichari	27	23	31	65	745	6.40	5.10	90	7
Cuzco	Febrero	La Convencion	Pichari	26.75	23	30.5	88	745	6.30	5.10	90	7
Cuzco	Marzo	La Convencion	Pichari	26.5	22	31	65	745	6.10	5.10	86	7
Cuzco	Abril	La Convencion	Pichari	26.25	21.5	31	20	745	6.00	4.90	75	7
Cuzco	Mayo	La Convencion	Pichari	26.20	21.00	31.40	7.00	745.00	6.00	4.70	58.00	7
Cuzco	Junio	La Convencion	Pichari	25.75	20.50	31.00	4.00	745.00	5.80	4.70	55.00	7
Cuzco	Julio	La Convencion	Pichari	25.50	20.00	31.00	4.00	745.00	6.00	4.90	45.00	7
Cuzco	Agosto	La Convencion	Pichari	26.50	21.00	32.00	7.00	745.00	6.30	5.30	47.00	7
Cuzco	Septiembre	La Convencion	Pichari	26.75	21.5	32	16	745	6.70	5.30	65	7
Cuzco	Octubre	La Convencion	Pichari	27.5	22	33	33	745	6.80	5.30	75	7
Cuzco	Noviembre	La Convencion	Pichari	27.5	23	32	43	745	6.70	5.20	83	7
Cuzco	Diciembre	La Convencion	Pichari	27	23	31	57	745	6.60	5.00	88	7
Huancavelica	Enero	Castrovirreyna	Arma	6	1	11	11.5	3950	8.90	6.20	82	15
Huancavelica	Febrero	Castrovirreyna	Arma	6.15	1.00	11.30	13.00	3950.00	8.30	6.00	76.00	15
Huancavelica	Marzo	Castrovirreyna	Arma	6.50	1.00	12.00	10.00	3950.00	8.10	5.80	83.00	15
Huancavelica	Abril	Castrovirreyna	Arma	6.15	0.50	11.80	3.00	3950.00	8.30	6.00	65.00	15
Huancavelica	Mayo	Castrovirreyna	Arma	4.75	-1.00	10.50	1.00	3950.00	9.20	5.90	43.00	15
Huancavelica	Junio	Castrovirreyna	Arma	4	-2	10	0	3950	9.60	5.80	42	15
Huancavelica	Julio	Castrovirreyna	Arma	4	-2	10	0	3950	10.00	6.00	31	15
Huancavelica	Agosto	Castrovirreyna	Arma	4.25	-1.5	10	0	3950	10.30	6.50	32	15
Huancavelica	Septiembre	Castrovirreyna	Arma	5.25	0	10.5	3	3950	10.00	6.90	48	15
Huancavelica	Octubre	Castrovirreyna	Arma	5.55	0.3	10.8	5	3950	9.80	6.90	65	15

Huancavelica	Noviembre	Castrovirreyna	Arma	5.75	0.5	11	5	3950	9.80	6.90	68	15
Huancavelica	Diciembre	Castrovirreyna	Arma	6	1	11	8	3950	9.30	6.50	77	15
Huancavelica	Enero	Churcampa	Churcampa	9.5	5	14	60	3846	9.00	5.50	89	13
Huancavelica	Febrero	Churcampa	Churcampa	9.5	5	14	81	3846	8.70	5.50	90	13
Huancavelica	Marzo	Churcampa	Churcampa	9.5	5	14	60	3846	8.30	5.40	88	13
Huancavelica	Abril	Churcampa	Churcampa	9	4	14	13	3846	8.00	5.20	75	13
Huancavelica	Mayo	Churcampa	Churcampa	8.50	3.00	14.00	4.00	3846.00	7.80	5.00	62.00	13
Huancavelica	Junio	Churcampa	Churcampa	8.00	2.00	14.00	4.00	3846.00	8.20	5.00	60.00	13
Huancavelica	Julio	Churcampa	Churcampa	8.00	2.00	14.00	4.00	3846.00	8.40	5.30	52.00	13
Huancavelica	Agosto	Churcampa	Churcampa	9	3	15	4	3846	9.30	5.50	55	13
Huancavelica	Septiembre	Churcampa	Churcampa	10	5	15	13	3846	9.60	5.60	73	13
Huancavelica	Octubre	Churcampa	Churcampa	9.5	5	14	25	3846	9.40	5.80	80	13
Huancavelica	Noviembre	Churcampa	Churcampa	9.5	5	14	40	3846	9.20	5.70	82	13
Huancavelica	Diciembre	Churcampa	Churcampa	9.5	5	14	60	3846	9.00	5.50	85	13
Huancavelica	Enero	Tayacaja	Colcabamba	11.15	6	16.3	55	3557	8.70	5.60	90	11
Huancavelica	Febrero	Tayacaja	Colcabamba	11.00	6.00	16.00	65.00	3557.00	8.80	5.50	90.00	11
Huancavelica	Marzo	Tayacaja	Colcabamba	11.00	6.00	16.00	50.00	3557.00	8.60	5.50	87.00	11
Huancavelica	Abril	Tayacaja	Colcabamba	10.50	5.00	16.00	13.00	3557.00	8.30	5.40	75.00	11
Huancavelica	Mayo	Tayacaja	Colcabamba	10.55	4.80	16.30	5.00	3557.00	7.90	5.30	63.00	11
Huancavelica	Junio	Tayacaja	Colcabamba	10.25	4.5	16	3	3557	8.10	5.10	57	11
Huancavelica	Julio	Tayacaja	Colcabamba	10	4	16	3	3557	8.50	5.30	50	11
Huancavelica	Agosto	Tayacaja	Colcabamba	10.5	4.5	16.5	3	3557	9.20	5.80	53	11
Huancavelica	Septiembre	Tayacaja	Colcabamba	11	5	17	13	3557	9.80	5.80	68	11
Huancavelica	Octubre	Tayacaja	Colcabamba	11.4	5.8	17	21	3557	9.70	6.00	80	11
Huancavelica	Noviembre	Tayacaja	Colcabamba	11.4	6	16.8	27	3557	9.30	5.90	82	11
Huancavelica	Diciembre	Tayacaja	Colcabamba	11.25	6	16.5	45	3557	9.00	5.80	87	11
Huánuco	Enero	Pachitea	Chaglla	12	8.5	15.5	80	3011	7.80	5.00	89	10

Huánuco	Febrero	Pachitea	Chaglla	11.75	8.5	15	88	3011	7.30	5.10	91	10
Huánuco	Marzo	Pachitea	Chaglla	12	8.5	15.5	75	3011	6.70	5.00	87	10
Huánuco	Abril	Pachitea	Chaglla	12	8.2	15.8	42	3011	6.50	5.20	71	10
Huánuco	Mayo	Pachitea	Chaglla	11.85	7.5	16.2	24	3011	6.50	5.30	55.5	10
Huánuco	Junio	Pachitea	Chaglla	11.35	6.5	16.2	20	3011	6.70	5.30	47	10
Huánuco	Julio	Pachitea	Chaglla	11.25	6	16.5	12	3011	7.00	5.50	40	10
Huánuco	Agosto	Pachitea	Chaglla	12	7	17	12	3011	7.80	5.90	49.2	10
Huánuco	Septiembre	Pachitea	Chaglla	12.95	7.90	18.00	23.00	3011.00	8.00	6.00	58.00	10
Huánuco	Octubre	Pachitea	Chaglla	12.50	8.00	17.00	50.00	3011.00	7.90	5.70	73.00	10
Huánuco	Noviembre	Pachitea	Chaglla	12.30	8.00	16.60	70.00	3011.00	7.80	5.40	82.00	10
Huánuco	Diciembre	Pachitea	Chaglla	12.10	8.00	16.20	75.00	3011.00	7.70	5.10	87.00	10
Huánuco	Enero	Huamalies	Jacas_Grande	9	5	13	90	3617	9.80	5.30	92	10
Huánuco	Febrero	Huamalies	Jacas_Grande	9	5	13	102	3617	9.00	5.20	93	10
Huánuco	Marzo	Huamalies	Jacas_Grande	9	5	13	80	3617	9.80	5.20	91.5	10
Huánuco	Abril	Huamalies	Jacas_Grande	8.9	4.8	13	53	3617	9.70	5.35	80	10
Huánuco	Mayo	Huamalies	Jacas_Grande	8.25	3.5	13	34	3617	9.10	5.50	62	10
Huánuco	Junio	Huamalies	Jacas_Grande	7.25	2	12.5	20	3617	10.00	5.60	55	10
Huánuco	Julio	Huamalies	Jacas_Grande	7	1	13	13	3617	10.40	6.00	47	10
Huánuco	Agosto	Huamalies	Jacas_Grande	8.00	2.00	14.00	13.00	3617.00	12.00	6.30	50.00	10
Huánuco	Septiembre	Huamalies	Jacas_Grande	9.25	3.50	15.00	25.00	3617.00	12.50	6.40	66.00	10
Huánuco	Octubre	Huamalies	Jacas_Grande	9.25	4.00	14.50	60.00	3617.00	11.00	6.00	80.00	10
Huánuco	Noviembre	Huamalies	Jacas_Grande	9.15	4.30	14.00	77.00	3617.00	10.00	5.80	85.00	10
Huánuco	Diciembre	Huamalies	Jacas_Grande	8.75	4.5	13	90	3617	9.60	5.40	88	10
Huánuco	Enero	Puerto_Inca	Puerto_Inca	27.25	23.00	31.50	120.00	205.00	3.20	5.20	82.00	8
Huánuco	Febrero	Puerto_Inca	Puerto_Inca	26.75	23	30.5	138	205	3.00	5.10	83	8
Huánuco	Marzo	Puerto_Inca	Puerto_Inca	26.9	23	30.8	120	205	2.80	5.00	80	8
Huánuco	Abril	Puerto_Inca	Puerto_Inca	27.15	23	31.3	75	205	2.80	5.10	65	8

Huánuco	Mayo	Puerto_Inca	Puerto_Inca	27	22.5	31.5	50	205	3.00	5.20	17	8
Huánuco	Junio	Puerto_Inca	Puerto_Inca	26.9	21.8	32	40	205	3.00	5.20	40	8
Huánuco	Julio	Puerto_Inca	Puerto_Inca	26.5	21	32	25	205	3.20	5.50	35	8
Huánuco	Agosto	Puerto_Inca	Puerto_Inca	27.45	21.9	33	25	205	3.30	5.80	34	8
Huánuco	Septiembre	Puerto_Inca	Puerto_Inca	28	22.5	33.5	50	205	3.40	6.10	48	8
Huánuco	Octubre	Puerto_Inca	Puerto_Inca	28.00	23.00	33.00	75.00	205.00	3.25	5.80	60.00	8
Huánuco	Noviembre	Puerto_Inca	Puerto_Inca	27.50	23.00	32.00	100.00	205.00	3.20	5.50	75.00	8
Huánuco	Diciembre	Puerto_Inca	Puerto_Inca	27.40	23.00	31.80	110.00	205.00	3.20	5.20	78.00	8
Ica	Enero	Chincha	El Carmen	23.5	20	27	1	146	12.90	6.80	75	15
Ica	Febrero	Chincha	El Carmen	24.5	21	28	2	146	12.00	6.30	80	15
Ica	Marzo	Chincha	El Carmen	23.65	20.3	27	1	146	12.00	6.20	77	15
Ica	Abril	Chincha	El Carmen	22.50	20.00	25.00	0.00	146.00	11.90	6.20	54.00	15
Ica	Mayo	Chincha	El Carmen	20.65	17.30	24.00	0.00	146.00	11.90	5.80	38.00	15
Ica	Junio	Chincha	El Carmen	20.50	17.00	24.00	0.00	146.00	12.20	5.60	38.00	15
Ica	Julio	Chincha	El Carmen	19.50	16.00	23.00	0.00	146.00	12.90	6.00	30.00	15
Ica	Agosto	Chincha	El Carmen	19.5	16	23	0	146	13.40	6.50	26	15
Ica	Septiembre	Chincha	El Carmen	20.5	17	24	0.3	146	13.90	7.10	40	15
Ica	Octubre	Chincha	El Carmen	21	17.5	24.5	1	146	13.80	7.20	53	15
Ica	Noviembre	Chincha	El Carmen	22	19	25	0.3	146	13.80	7.40	58	15
Ica	Diciembre	Chincha	El Carmen	23	20	26	0.8	146	13.20	6.80	70	15
Ica	Enero	Ica	Ica	23	19	27	1.8	408	14.00	6.80	73	16
Ica	Febrero	Ica	Ica	24	20	28	3	408	13.50	6.50	78	16
Ica	Marzo	Ica	Ica	23.25	19	27.5	1.8	408	13.30	6.30	75	16
Ica	Abril	Ica	Ica	23	19	27	0	408	13.00	6.20	53	16
Ica	Mayo	Ica	Ica	20.5	16	25	0.5	408	12.70	6.00	37	16
Ica	Junio	Ica	Ica	19.00	15.00	23.00	0.00	408.00	13.00	5.50	38.00	16
Ica	Julio	Ica	Ica	19.00	15.00	23.00	0.00	408.00	13.30	6.00	30.00	16

Ica	Agosto	Ica	Ica	19.25	15	23.5	0	408	14.00	6.50	27	16
Ica	Septiembre	Ica	Ica	19.5	15	24	0	408	14.30	7.20	40	16
Ica	Octubre	Ica	Ica	20.15	16	24.3	1	408	14.50	7.50	52	16
Ica	Noviembre	Ica	Ica	21	17	25	0.3	408	14.10	7.60	55	16
Ica	Diciembre	Ica	Ica	22	18	26	1	408	14.00	6.80	67	16
Junín	Enero	Jauja	Molinos	10.90	5.30	16.50	13.00	3449.00	10.00	5.70	90.00	7
Junín	Febrero	Jauja	Molinos	10.90	5.30	16.50	16.00	3449.00	10.00	5.70	91.00	7
Junín	Marzo	Jauja	Molinos	10.90	5.30	16.50	10.00	3449.00	10.00	5.60	88.00	7
Junín	Abril	Jauja	Molinos	10.75	5.00	16.50	3.00	3449.00	9.70	5.60	75.00	7
Junín	Mayo	Jauja	Molinos	10.5	4.5	16.5	0	3449	9.00	5.50	62	7
Junín	Junio	Jauja	Molinos	10	4	16	0	3449	9.20	5.40	56	7
Junín	Julio	Jauja	Molinos	9.5	3	16	0	3449	10.00	5.80	48	7
Junín	Agosto	Jauja	Molinos	10.25	4	16.5	1	3449	10.80	6.20	52	7
Junín	Septiembre	Jauja	Molinos	11	5	17	3	3449	11.20	6.40	66	7
Junín	Octubre	Jauja	Molinos	11.3	5.6	17	6	3449	10.60	6.30	79	7
Junín	Noviembre	Jauja	Molinos	11.4	6	16.8	6	3449	10.00	6.00	82	7
Junín	Diciembre	Jauja	Molinos	11.35	6	16.7	10	3449	9.80	5.80	88	7
Junín	Enero	Satipo	Satipo	26.50	22.00	31.00	45.00	629.00	5.50	5.00	89.00	19
Junín	Febrero	Satipo	Satipo	26.5	22	31	59	629	5.30	5.10	89	19
Junín	Marzo	Satipo	Satipo	26.5	22	31	50	629	5.00	5.10	87	19
Junín	Abril	Satipo	Satipo	26.5	22	31	13	629	5.00	5.10	75	19
Junín	Mayo	Satipo	Satipo	26.5	22	31	5	629	5.10	5.00	55	19
Junín	Junio	Satipo	Satipo	26.5	22	31	4	629	5.00	4.90	47	19
Junín	Julio	Satipo	Satipo	26	21	31	3	629	5.20	5.20	38	19
Junín	Agosto	Satipo	Satipo	27	22	32	4	629	5.50	5.60	40	19
Junín	Septiembre	Satipo	Satipo	27.5	22	33	13	629	5.80	5.80	57	19
Junín	Octubre	Satipo	Satipo	27.50	23.00	32.00	26.00	629.00	5.70	5.60	75.00	19

Junín	Noviembre	Satipo	Satipo	27.00	23.00	31.00	30.00	629.00	5.60	5.40	82.00	19
Junín	Diciembre	Satipo	Satipo	27.00	23.00	31.00	42.00	629.00	5.50	5.10	85.00	19
La Libertad	Enero	Viru	Viru	21.75	18.5	25	4	75	10.80	6.60	70	15
La Libertad	Febrero	Viru	Viru	23	20	26	5	75	10.30	6.20	77	15
La Libertad	Marzo	Viru	Viru	23.50	21.00	26.00	5.00	75.00	10.20	6.00	74.00	15
La Libertad	Abril	Viru	Viru	22.00	19.00	25.00	6.00	75.00	11.00	6.20	51.00	15
La Libertad	Mayo	Viru	Viru	21.00	18.00	24.00	2.50	75.00	11.80	6.00	38.00	15
La Libertad	Junio	Viru	Viru	19.65	17.30	22.00	0.00	75.00	12.00	5.90	35.00	15
La Libertad	Julio	Viru	Viru	19.4	17.3	21.5	0	75	12.00	6.20	28	15
La Libertad	Agosto	Viru	Viru	19.1	17.2	21	0	75	12.40	6.70	28	15
La Libertad	Septiembre	Viru	Viru	19	17	21	2.5	75	12.40	7.10	38	15
La Libertad	Octubre	Viru	Viru	19.2	17.4	21	3	75	11.90	7.00	51	15
La Libertad	Noviembre	Viru	Viru	19.8	17.6	22	2	75	11.30	7.10	55	15
La Libertad	Diciembre	Viru	Viru	21.5	18	25	3	75	11.00	6.70	64	15
Lambayeque	Enero	Lambayeque	Olmos	28	22	34	14	175	10.30	5.90	71	13
Lambayeque	Febrero	Lambayeque	Olmos	29	23	35	24	175	9.70	5.60	78	13
Lambayeque	Marzo	Lambayeque	Olmos	28.40	22.00	34.80	22.00	175.00	9.00	5.60	75.00	13
Lambayeque	Abril	Lambayeque	Olmos	27.65	21.50	33.80	13.00	175.00	9.50	5.60	60.00	13
Lambayeque	Mayo	Lambayeque	Olmos	26.25	20.50	32.00	3.00	175.00	9.90	5.60	40.00	13
Lambayeque	Junio	Lambayeque	Olmos	25.50	20.00	31.00	0.00	175.00	9.90	5.70	35.00	13
Lambayeque	Julio	Lambayeque	Olmos	24.75	19.5	30	0	175	9.90	6.00	28	13
Lambayeque	Agosto	Lambayeque	Olmos	24.5	19	30	0	175	10.10	6.30	30	13
Lambayeque	Septiembre	Lambayeque	Olmos	24.75	19	30.5	0	175	0.70	6.50	40	13
Lambayeque	Octubre	Lambayeque	Olmos	25	19	31	3	175	11.00	6.30	52	13
Lambayeque	Noviembre	Lambayeque	Olmos	26	20	32	3	175	11.30	6.40	60	13
Lambayeque	Diciembre	Lambayeque	Olmos	27.8	21.8	33.8	7	175	10.70	6.10	67	13
Lima	Enero	Huaura	Huaura	22.9	19	26.8	2	72	13.80	6.50	75	14

Lima	Febrero	Huaura	Huaura	23.9	20	27.8	3	72	12.30	6.20	80	14
Lima	Marzo	Huaura	Huaura	23.25	19	27.5	3	72	12.20	6.00	78	14
Lima	Abril	Huaura	Huaura	20	16	24	2	72	14.00	6.10	55	14
Lima	Mayo	Huaura	Huaura	19.80	17.00	22.60	1.00	72.00	14.50	6.00	38.00	14
Lima	Junio	Huaura	Huaura	17.90	16.00	19.80	0.00	72.00	15.80	5.70	38.00	14
Lima	Julio	Huaura	Huaura	17.05	15.00	19.10	0.00	72.00	16.00	6.00	29.00	14
Lima	Agosto	Huaura	Huaura	16.85	15.00	18.70	0.00	72.00	16.00	6.50	27.00	14
Lima	Septiembre	Huaura	Huaura	16.65	14	19.3	0.5	72	15.40	7.10	37	14
Lima	Octubre	Huaura	Huaura	18	15	21	1	72	14.70	7.30	53	14
Lima	Noviembre	Huaura	Huaura	19.55	16.5	22.6	1	72	14.00	7.10	60	14
Lima	Diciembre	Huaura	Huaura	21.4	18	24.8	1	72	13.50	6.70	70	14
Loreto	Enero	Maynas	Indiana	27.50	24.00	31.00	246.00	94.00	2.90	4.70	80.00	12
Loreto	Febrero	Maynas	Indiana	27.00	24.00	30.00	230.00	94.00	2.80	4.80	83.00	12
Loreto	Marzo	Maynas	Indiana	26.5	23	30	260	94	2.80	4.70	81	12
Loreto	Abril	Maynas	Indiana	26.5	23	30	260	94	2.80	4.70	78	12
Loreto	Mayo	Maynas	Indiana	26.5	23	30	210	94	2.80	4.70	63	12
Loreto	Junio	Maynas	Indiana	26.5	23	30	150	94	2.90	4.80	47	12
Loreto	Julio	Maynas	Indiana	26	22	30	121	94	3.00	5.20	40	12
Loreto	Agosto	Maynas	Indiana	26.5	22	31	122	94	3.00	5.40	45	12
Loreto	Septiembre	Maynas	Indiana	27.5	23	32	125	94	2.90	5.50	55	12
Loreto	Octubre	Maynas	Indiana	27.5	23	32	200	94	2.80	5.20	70	12
Loreto	Noviembre	Maynas	Indiana	27.00	23.00	31.00	210.00	94.00	2.80	4.80	79.00	12
Loreto	Diciembre	Maynas	Indiana	27.00	23.00	31.00	230.00	94.00	3.00	4.80	80.00	12
Loreto	Enero	Loreto	Parinari	27.00	22.50	31.50	200.00	118.00	2.70	5.00	81.00	9
Loreto	Febrero	Loreto	Parinari	26.65	22.30	31.00	210.00	118.00	2.60	4.90	84.00	9
Loreto	Marzo	Loreto	Parinari	26.5	22	31	235	118	2.50	4.80	82	9
Loreto	Abril	Loreto	Parinari	26.35	22	30.7	228	118	2.60	4.80	75	9



Loreto	Mayo	Loreto	Parinari	26	21.5	30.5	180	118	2.70	4.90	55	9
Loreto	Junio	Loreto	Parinari	25.8	21.3	30.3	130	118	2.75	5.00	45	9
Loreto	Julio	Loreto	Parinari	25.5	21	30	97	118	2.80	5.30	35	9
Loreto	Agosto	Loreto	Parinari	26.5	21.5	31.5	100	118	2.90	5.60	39	9
Loreto	Septiembre	Loreto	Parinari	27.5	22	33	120	118	2.70	5.80	52	9
Loreto	Octubre	Loreto	Parinari	27.25	22.5	32	170	118	2.60	5.70	69	9
Loreto	Noviembre	Loreto	Parinari	27.15	22.50	31.80	195.00	118.00	2.60	5.00	77.00	9
Loreto	Diciembre	Loreto	Parinari	27.10	22.50	31.70	200.00	118.00	2.65	5.00	80.00	9
Madre_de_Dios	Enero	Tahuamanu	Ibeia	26	22	30	240	306	2.80	5.20	86	8
Madre_de_Dios	Febrero	Tahuamanu	Ibeia	26	22	30	245	306	2.70	5.20	85	8
Madre_de_Dios	Marzo	Tahuamanu	Ibeia	26	22	30	195	306	2.60	5.10	82	8
Madre_de_Dios	Abril	Tahuamanu	Ibeia	25.75	21.5	30	125	306	2.70	5.00	70	8
Madre_de_Dios	Mayo	Tahuamanu	Ibeia	24.5	19.5	29.5	70	306	3.00	5.10	55	8
Madre_de_Dios	Junio	Tahuamanu	Ibeia	24.25	19	29.5	27	306	3.10	5.20	45	8
Madre_de_Dios	Julio	Tahuamanu	Ibeia	24.5	18	31	23	306	3.30	5.50	32	8
Madre_de_Dios	Agosto	Tahuamanu	Ibeia	25.9	18.8	33	25	306	3.30	5.75	33	8
Madre_de_Dios	Septiembre	Tahuamanu	Ibeia	26.50	20.00	33.00	75.00	306.00	3.20	5.80	49.00	8
Madre_de_Dios	Octubre	Tahuamanu	Ibeia	26.50	21.00	32.00	125.00	306.00	2.80	5.70	66.00	8
Madre_de_Dios	Noviembre	Tahuamanu	Ibeia	25.75	21.50	30.00	175.00	306.00	2.80	5.50	77.00	8
Madre_de_Dios	Diciembre	Tahuamanu	Ibeia	25.50	22.00	29.00	200.00	306.00	2.90	5.30	82.00	8
Madre_de_Dios	Enero	Tahuamanu	Iñapari	25	22.5	27.5	215	240	2.80	5.10	86	9
Madre_de_Dios	Febrero	Tahuamanu	Iñapari	25	22.5	27.5	237	240	2.70	5.10	85	9
Madre_de_Dios	Marzo	Tahuamanu	Iñapari	25	22.5	27.5	200	240	2.60	5.00	82	9
Madre_de_Dios	Abril	Tahuamanu	Iñapari	24.75	22	27.5	260	240	2.70	5.00	75	9
Madre_de_Dios	Mayo	Tahuamanu	Iñapari	24.5	21	28	75	240	3.00	5.00	55	9
Madre_de_Dios	Junio	Tahuamanu	Iñapari	24.5	20	29	22	240	3.20	5.10	45	9
Madre_de_Dios	Julio	Tahuamanu	Iñapari	25.25	19	31.5	19	240	3.30	5.50	33	9

Madre_de_Dios	Agosto	Tahuamanu	Iñapari	27.5	21	34	25	240	3.30	5.80	35	9
Madre_de_Dios	Septiembre	Tahuamanu	Iñapari	28.25	22.50	34.00	75.00	240.00	3.20	5.90	50.00	9
Madre_de_Dios	Octubre	Tahuamanu	Iñapari	27.75	23.00	32.50	125.00	240.00	2.80	5.90	67.00	9
Madre_de_Dios	Noviembre	Tahuamanu	Iñapari	26.75	23.00	30.50	175.00	240.00	2.80	5.50	76.00	9
Madre_de_Dios	Diciembre	Tahuamanu	Iñapari	25.75	23.00	28.50	200.00	240.00	2.80	5.30	82.00	9
Madre_de_Dios	Enero	Tambopata	Tambopata	26.5	23	30	295	224	2.80	5.10	87	8
Madre_de_Dios	Febrero	Tambopata	Tambopata	26.5	23	30	290	224	2.70	5.10	85	8
Madre_de_Dios	Marzo	Tambopata	Tambopata	26.5	23	30	200	224	2.70	5.10	82	8
Madre_de_Dios	Abril	Tambopata	Tambopata	26	22	30	140	224	2.80	5.00	70	8
Madre_de_Dios	Mayo	Tambopata	Tambopata	24.5	20	29	100	224	2.90	4.80	55	8
Madre_de_Dios	Junio	Tambopata	Tambopata	18.5	9	28	60	224	3.10	4.80	45	8
Madre_de_Dios	Julio	Tambopata	Tambopata	24	18	30	41	224	3.20	5.20	31	8
Madre_de_Dios	Agosto	Tambopata	Tambopata	25	19	31	41	224	3.20	5.40	32	8
Madre_de_Dios	Septiembre	Tambopata	Tambopata	26.00	20.00	32.00	70.00	224.00	3.10	5.60	55.00	8
Madre_de_Dios	Octubre	Tambopata	Tambopata	26.50	22.00	31.00	150.00	224.00	2.80	5.50	70.00	8
Madre_de_Dios	Noviembre	Tambopata	Tambopata	26.25	22.50	30.00	185.00	224.00	2.80	5.40	98.00	8
Madre_de_Dios	Diciembre	Tambopata	Tambopata	26.25	22.50	30.00	240.00	224.00	2.90	5.20	83.00	8
Moquegua	Enero	Mariscal Nieto	Torata	15	10	20	6	2213	12.00	7.20	75	4
Moquegua	Febrero	Mariscal Nieto	Torata	15.05	10.1	20	11	2213	11.50	6.90	78	4
Moquegua	Marzo	Mariscal Nieto	Torata	15.00	10.00	20.00	7.50	2213.00	11.00	6.70	68.00	4
Moquegua	Abril	Mariscal Nieto	Torata	14.25	8.50	20.00	2.00	2213.00	10.50	6.30	53.00	4
Moquegua	Mayo	Mariscal Nieto	Torata	13.25	7.50	19.00	0.00	2213.00	10.30	6.00	40.00	4
Moquegua	Junio	Mariscal Nieto	Torata	12.75	7.00	18.50	0.50	2213.00	10.10	5.50	38.00	4
Moquegua	Julio	Mariscal Nieto	Torata	12	6	18	1	2213	10.50	5.80	30	4
Moquegua	Agosto	Mariscal Nieto	Torata	12.4	6.3	18.5	0.5	2213	11.10	6.50	28	4
Moquegua	Septiembre	Mariscal Nieto	Torata	13.3	7.6	19	1	2213	12.00	7.30	40	4
Moquegua	Octubre	Mariscal Nieto	Torata	13.6	8.2	19	0.3	2213	12.00	7.90	50	4

Moquegua	Noviembre	Mariscal Nieto	Torata	14.5	9	20	1	2213	12.00	8.10	55	4
Moquegua	Diciembre	Mariscal Nieto	Torata	15	10	20	3	2213	11.80	7.50	65	4
Pasco	Enero	Oxapampa	Oxapampa	17.75	14	21.5	35	1814	6.10	4.90	90	17
Pasco	Febrero	Oxapampa	Oxapampa	17.75	14.00	21.50	43.00	1814.00	6.10	5.10	90.00	17
Pasco	Marzo	Oxapampa	Oxapampa	17.75	14.00	21.50	38.00	1814.00	5.80	5.00	88.00	17
Pasco	Abril	Oxapampa	Oxapampa	18.00	14.00	22.00	14.00	1814.00	5.60	5.00	75.00	17
Pasco	Mayo	Oxapampa	Oxapampa	17.90	13.80	22.00	7.00	1814.00	5.50	5.00	58.00	17
Pasco	Junio	Oxapampa	Oxapampa	17.75	13.5	22	4	1814	5.40	4.90	50	17
Pasco	Julio	Oxapampa	Oxapampa	17.5	13	22	2	1814	5.60	5.20	42	17
Pasco	Agosto	Oxapampa	Oxapampa	18.35	13.7	23	2	1814	6.00	5.60	43	17
Pasco	Septiembre	Oxapampa	Oxapampa	19	14	24	6	1814	6.40	5.80	57	17
Pasco	Octubre	Oxapampa	Oxapampa	18.5	14	23	25	1814	6.20	5.60	75	17
Pasco	Noviembre	Oxapampa	Oxapampa	18	14	22	27	1814	6.00	5.30	83	17
Pasco	Diciembre	Oxapampa	Oxapampa	18	14	22	37	1814	6.20	5.00	87.5	17
Piura	Enero	Piura	Piura	27	22	32	17	33	17.50	6.30	63	12
Piura	Febrero	Piura	Piura	28.5	24	33	34	33	14.00	6.00	76	12
Piura	Marzo	Piura	Piura	27.75	23	32.5	35	33	13.60	6.00	73	12
Piura	Abril	Piura	Piura	27.00	22.00	32.00	13.00	33.00	16.00	6.00	55.00	12
Piura	Mayo	Piura	Piura	25.50	21.00	30.00	2.00	33.00	17.50	6.00	38.00	12
Piura	Junio	Piura	Piura	23.25	19.00	27.50	0.00	33.00	2.00	5.90	31.00	12
Piura	Julio	Piura	Piura	22.5	18	27	0	33	21.00	6.20	27	12
Piura	Agosto	Piura	Piura	22	17	27	0	33	21.20	6.60	26	12
Piura	Septiembre	Piura	Piura	23	18	28	0	33	21.40	7.00	35	12
Piura	Octubre	Piura	Piura	23.8	19	28.6	0.5	33	21.00	7.00	46	12
Piura	Noviembre	Piura	Piura	24.5	20	29	1.7	33	19.00	6.90	95	12
Piura	Diciembre	Piura	Piura	26.5	22	31	13	33	18.00	6.50	62	12
San_Martin	Enero	Mariscal_Caceres	Huicungo	27.65	23.00	32.30	58.00	301.00	3.60	5.60	82.00	13

San_Martin	Febrero	Mariscal_Caceres	Huicungo	27.5	23	32	88	301	3.40	5.30	86	13
San_Martin	Marzo	Mariscal_Caceres	Huicungo	27.35	23	31.7	90	301	3.20	5.20	85	13
San_Martin	Abril	Mariscal_Caceres	Huicungo	27.2	22.7	31.7	80	301	3.20	5.30	70	13
San_Martin	Mayo	Mariscal_Caceres	Huicungo	27.25	22.5	32	50	301	3.20	5.20	50	13
San_Martin	Junio	Mariscal_Caceres	Huicungo	27.15	22	32.3	40	301	3.40	5.40	45	13
San_Martin	Julio	Mariscal_Caceres	Huicungo	27.25	22	32.5	27	301	3.50	5.65	35	13
San_Martin	Agosto	Mariscal_Caceres	Huicungo	28.55	22.7	34.4	24	301	3.70	6.00	35	13
San_Martin	Septiembre	Mariscal_Caceres	Huicungo	29	23	35	50	301	3.80	6.40	48	13
San_Martin	Octubre	Mariscal_Caceres	Huicungo	28.65	23.30	34.00	75.00	301.00	3.70	6.10	64.00	13
San_Martin	Noviembre	Mariscal_Caceres	Huicungo	28.50	23.50	33.50	80.00	301.00	3.50	5.80	75.00	13
San_Martin	Diciembre	Mariscal_Caceres	Huicungo	27.75	23.50	32.00	67.00	301.00	3.50	5.70	79.00	13
San_Martin	Enero	Lamas	Lamas	25.25	21.00	29.50	69.00	814.00	3.70	5.50	81.00	12
San_Martin	Febrero	Lamas	Lamas	25	21	29	100	814	3.40	5.30	85	12
San_Martin	Marzo	Lamas	Lamas	24.5	21	28	105	814	3.20	5.20	83	12
San_Martin	Abril	Lamas	Lamas	24.25	21	27.5	100	814	3.00	5.20	70	12
San_Martin	Mayo	Lamas	Lamas	24	20	28	60	814	3.00	5.20	55	12
San_Martin	Junio	Lamas	Lamas	23.75	19	28.5	50	814	3.20	5.30	45	12
San_Martin	Julio	Lamas	Lamas	25	20	30	40	814	3.30	5.50	36	12
San_Martin	Agosto	Lamas	Lamas	26	21	31	31	814	3.40	6.00	35	12
San_Martin	Septiembre	Lamas	Lamas	26.5	21	32	60	814	3.50	6.30	50	12
San_Martin	Octubre	Lamas	Lamas	26.00	21.00	31.00	75.00	814.00	3.40	6.00	65.00	12
San_Martin	Noviembre	Lamas	Lamas	25.25	21.00	29.50	91.00	814.00	3.50	5.80	73.00	12
San_Martin	Diciembre	Lamas	Lamas	25.00	21.00	29.00	75.00	814.00	3.80	5.60	75.00	12
San_Martin	Enero	Tocache	Tocache	26.5	23	30	135	498	5.00	5.30	76	12
San_Martin	Febrero	Tocache	Tocache	26.5	23	30	155	498	4.80	5.20	88	12
San_Martin	Marzo	Tocache	Tocache	26.5	23	30	135	498	4.70	5.10	86	12
San_Martin	Abril	Tocache	Tocache	26.25	22.5	30	100	498	4.50	5.20	70	12

San_Martin	Mayo	Tocache	Tocache	26.15	22	30.3	75	498	44.40	5.30	53	12
San_Martin	Junio	Tocache	Tocache	26.05	21.5	30.6	50	498	4.40	5.30	45	12
San_Martin	Julio	Tocache	Tocache	26	21	31	37	498	4.80	5.50	38	12
San_Martin	Agosto	Tocache	Tocache	26.75	21.5	32	34	498	5.00	6.00	38	12
San_Martin	Septiembre	Tocache	Tocache	27.75	22.50	33.00	65.00	498.00	5.20	6.20	54.00	12
San_Martin	Octubre	Tocache	Tocache	27.40	23.30	31.50	110.00	498.00	5.00	5.90	68.00	12
San_Martin	Noviembre	Tocache	Tocache	26.75	23.00	30.50	135.00	498.00	5.00	5.70	77.00	12
San_Martin	Diciembre	Tocache	Tocache	26.50	23.00	30.00	138.00	498.00	5.00	5.40	82.00	12
Tacna	Enero	Jorge Basadre	Locumba	21.5	17	26	2.7	598	11.90	7.20	68	7
Tacna	Febrero	Jorge Basadre	Locumba	21.5	17	26	3	598	11.50	7.00	71.5	7
Tacna	Marzo	Jorge Basadre	Locumba	20.5	16.5	24.5	2.5	598	10.70	6.70	60	7
Tacna	Abril	Jorge Basadre	Locumba	19.25	15	23.5	0.3	598	9.70	6.00	45	7
Tacna	Mayo	Jorge Basadre	Locumba	18.00	14.00	22.00	0.00	598.00	8.60	5.50	35.00	7
Tacna	Junio	Jorge Basadre	Locumba	15.75	11.50	20.00	0.50	598.00	7.80	5.20	32.00	7
Tacna	Julio	Jorge Basadre	Locumba	15	11	19	1	598	8.00	5.50	25	7
Tacna	Agosto	Jorge Basadre	Locumba	15.5	11.5	19.5	0	598	8.40	6.20	25	7
Tacna	Septiembre	Jorge Basadre	Locumba	16	12	20	1	598	9.70	7.20	33	7
Tacna	Octubre	Jorge Basadre	Locumba	17	13	21	0	598	10.70	7.70	45	7
Tacna	Noviembre	Jorge Basadre	Locumba	18	14	22	0.2	598	11.70	8.00	50	7
Tacna	Diciembre	Jorge Basadre	Locumba	20	16	24	1	598	12.00	7.50	60	7
Ucayali	Enero	Coronel Portillo	Masisea	27.00	23.00	31.00	135.00	156.00	3.00	5.20	82.00	8
Ucayali	Febrero	Coronel Portillo	Masisea	27.00	23.00	31.00	160.00	156.00	2.70	5.00	82.00	8
Ucayali	Marzo	Coronel Portillo	Masisea	27	23	31	145	156	2.60	5.00	80	8
Ucayali	Abril	Coronel Portillo	Masisea	27	23	31	120	156	2.70	5.00	70	8
Ucayali	Mayo	Coronel Portillo	Masisea	26.75	22.5	31	65	156	2.80	5.20	50	8
Ucayali	Junio	Coronel Portillo	Masisea	26.5	22	31	50	156	2.80	5.40	40	8
Ucayali	Julio	Coronel Portillo	Masisea	26	21	31	35	156	2.90	5.50	33	8

Ucayali	Agosto	Coronel Portillo	Masisea	26.5	21.5	31.5	35	156	3.00	5.90	32	8
Ucayali	Septiembre	Coronel Portillo	Masisea	27.25	22.5	32	70	156	3.00	6.10	50	8
Ucayali	Octubre	Coronel Portillo	Masisea	27.1	22.7	31.5	110	156	3.00	5.80	65	8
Ucayali	Noviembre	Coronel Portillo	Masisea	27.00	23.00	31.00	130.00	156.00	2.90	5.50	75.00	8
Ucayali	Diciembre	Coronel Portillo	Masisea	27.00	23.00	31.00	125.00	156.00	3.00	5.20	78.00	8
Ucayali	Enero	Coronel Portillo	Nueva Requena	27.00	23.00	31.00	155.00	151.00	2.80	5.10	82.00	7
Ucayali	Febrero	Coronel Portillo	Nueva Requena	26.50	23.00	30.00	180.00	151.00	2.60	5.00	84.00	7
Ucayali	Marzo	Coronel Portillo	Nueva Requena	26.50	23.00	30.00	152.00	151.00	2.50	4.90	80.00	7
Ucayali	Abril	Coronel Portillo	Nueva Requena	26.5	23	30	120	151	2.60	5.10	67	7
Ucayali	Mayo	Coronel Portillo	Nueva Requena	26.25	22.5	30	75	151	2.70	5.20	50	7
Ucayali	Junio	Coronel Portillo	Nueva Requena	26	22	30	60	151	2.70	5.20	41	7
Ucayali	Julio	Coronel Portillo	Nueva Requena	25.5	21	30	40	151	2.80	5.50	35	7
Ucayali	Agosto	Coronel Portillo	Nueva Requena	26.25	21.5	31	40	151	2.90	5.90	35	7
Ucayali	Septiembre	Coronel Portillo	Nueva Requena	27	22	32	75	151	3.00	6.10	50	7
Ucayali	Octubre	Coronel Portillo	Nueva Requena	27	23	31	120	151	2.85	5.90	62	7
Ucayali	Noviembre	Coronel Portillo	Nueva Requena	26.5	23	30	145	151	2.80	5.50	75	7
Ucayali	Diciembre	Coronel Portillo	Nueva Requena	26.50	23.00	30.00	145.00	151.00	2.80	5.20	78.00	7
Ucayali	Enero	Atalaya	Sepahua	26.35	22.70	30.00	135.00	283.00	3.10	5.00	85.00	7
Ucayali	Febrero	Atalaya	Sepahua	26.00	22.50	29.50	143.00	283.00	3.00	5.10	85.00	7
Ucayali	Marzo	Atalaya	Sepahua	26.00	22.50	29.50	135.00	283.00	2.90	5.00	80.00	7
Ucayali	Abril	Atalaya	Sepahua	26.15	22.5	29.8	75	283	3.00	5.00	68	7
Ucayali	Mayo	Atalaya	Sepahua	26.15	22	30.3	30	283	3.20	5.00	50	7
Ucayali	Junio	Atalaya	Sepahua	21.5	21.5	21.5	20	283	3.40	5.10	42	7
Ucayali	Julio	Atalaya	Sepahua	27.25	21.5	33	13	283	3.40	5.30	33	7
Ucayali	Agosto	Atalaya	Sepahua	28.75	23	34.5	16	283	3.40	5.70	35	7
Ucayali	Septiembre	Atalaya	Sepahua	29.25	24	34.5	37	283	3.40	5.90	47	7
Ucayali	Octubre	Atalaya	Sepahua	29	24	34	75	283	3.30	5.70	55	7

Ucayali	Noviembre	Atalaya	Sepahua	27.65	23.7	31.6	97	283	3.30	5.50	75	7
Ucayali	Diciembre	Atalaya	Sepahua	26.65	23.30	30.00	120.00	283.00	3.20	5.30	82.00	7



### Anexo 3: Datos de entrada para el modelo AMPL

**param** rend :=

1	13
2	10
3	7
4	6
5	5
6	4
7	24
8	11
9	11
10	11
11	10
12	21
13	19
14	8
15	15
16	15
17	7
18	15
19	13
20	11
21	10
22	10
23	8
24	19
25	7
26	12
27	9
28	9
29	8
30	8
31	17
32	13
33	12
34	12
35	8
36	7
37	7;

**param** pob :=

1	34.55
2	34.55
3	34.55
4	34.55
5	34.55
6	34.55
7	34.55
8	34.55
9	34.55
10	34.55
11	34.55
12	41.85
13	41.85
14	41.85
15	23.1
16	23.1
17	23.1





18 34.55  
19 34.55  
20 34.55  
21 34.55  
22 34.55  
23 34.55  
24 23.1  
25 23.1  
26 34.55  
27 34.55  
28 3.1  
29 3.1  
30 3.1  
31 34.55  
32 23.1  
33 23.1  
34 23.1  
35 12.55  
36 12.55  
37 12.55;

param inf:=  
1 85.35  
2 85.35  
3 85.35  
4 88.04  
5 88.04  
6 88.04  
7 87.10  
8 87.10  
9 87.10  
10 87.10  
11 87.10  
12 89.34  
13 89.34  
14 89.34  
15 81.61  
16 81.61  
17 81.61  
18 91.41  
19 91.41  
20 91.41  
21 87.30  
22 87.30  
23 87.30  
24 83.48  
25 83.48  
26 81.80  
27 81.80  
28 76.16  
29 76.16  
30 76.16  
31 80.90  
32 84.63  
33 84.63  
34 84.63  
35 77.58  
36 77.58  
37 77.58;



param ai:=  
 1 66.06  
 2 45.30  
 3 79.26  
 4 45.30  
 5 45.30  
 6 45.30  
 7 79.26  
 8 79.26  
 9 79.26  
 10 66.06  
 11 79.26  
 12 88.76  
 13 88.76  
 14 45.30  
 15 45.30  
 16 45.30  
 17 79.26  
 18 96.02  
 19 45.30  
 20 45.30  
 21 66.06  
 22 88.76  
 23 66.06  
 24 66.06  
 25 96.02  
 26 96.02  
 27 96.02  
 28 88.76  
 29 79.26  
 30 88.76  
 31 96.02  
 32 96.02  
 33 88.76  
 34 96.02  
 35 66.06  
 36 66.06  
 37 79.26;



param agua:  
 1 2 3 4 5 6 7 8 9 10 11 12:=  
 1 49 49 49 49 49 49 49 49 49 49 49 49  
 2 36 36 36 36 36 36 36 36 36 36 36 36  
 3 13 13 13 13 13 13 13 13 13 13 13 13  
 4 145 145 145 145 145 145 145 145 145 145 145 145  
 5 52 52 52 52 52 52 52 52 52 52 52 52  
 6 16 16 16 16 16 16 16 16 16 16 16 16  
 7 14 14 14 14 14 14 14 14 14 14 14 14  
 8 3 3 3 3 x<sup>e</sup> 3 3 3 3 3 3 3  
 9 70 70 70 70 70 70 70 70 70 70 70 70  
 10 62 62 62 62 62 62 62 62 62 62 62 62  
 11 59 59 59 59 59 59 59 59 59 59 59 59  
 12 136 136 136 136 136 136 136 136 136 136 136 136  
 13 32 32 32 32 32 32 32 32 32 32 32 32  
 14 81 81 81 81 81 81 81 81 81 81 81 81  
 15 41 41 41 41 41 41 41 41 41 41 41 41  
 16 56 56 56 56 56 56 56 56 56 56 56 56  
 17 122 122 122 122 122 122 122 122 122 122 122 122  
 18 51 51 51 51 51 51 51 51 51 51 51 51

19	24	24	24	24	24	24	24	24	24	24	24	24
20	100	100	100	100	100	100	100	100	100	100	100	100
21	40	40	40	40	40	40	40	40	40	40	40	40
22	111	111	111	111	111	111	111	111	111	111	111	111
23	347	347	347	347	347	347	347	347	347	347	347	347
24	123	123	123	123	123	123	123	123	123	123	123	123
25	52	52	52	52	52	52	52	52	52	52	52	52
26	552	552	552	552	552	552	552	552	552	552	552	552
27	183	183	183	183	183	183	183	183	183	183	183	183
28	2,487	2,487	2,487	2,487	2,487	2,487	2,487	2,487	2,487	2,487	2,487	2,487
29	3,462	3,462	3,462	3,462	3,462	3,462	3,462	3,462	3,462	3,462	3,462	3,462
30	427	427	427	427	427	427	427	427	427	427	427	427
31	70	70	70	70	70	70	70	70	70	70	70	70
32	1,641	1,641	1,641	1,641	1,641	1,641	1,641	1,641	1,641	1,641	1,641	1,641
33	16	16	16	16	16	16	16	16	16	16	16	16
34	187	187	187	187	187	187	187	187	187	187	187	187
35	2,361	2,361	2,361	2,361	2,361	2,361	2,361	2,361	2,361	2,361	2,361	2,361
36	1,292	1,292	1,292	1,292	1,292	1,292	1,292	1,292	1,292	1,292	1,292	1,292
37	377	377	377	377	377	377	377	377	377	377	377	377;

param t :=  
1 343,980  
2 4,004  
3 1,410  
4 15,110  
5 5,426  
6 1,690  
7 1,792  
8 406  
9 8,781  
10 7,815  
11 7,458  
12 13,789  
13 3,215  
14 8,233  
15 2,497  
16 3,415  
17 7,451  
18 3,153  
19 1,463  
20 6,187  
21 6,915  
22 19,391  
23 60,432  
24 27,875  
25 11,889  
26 151,909  
27 50,391  
28 585,367  
29 814,858  
30 100,453  
31 9,819  
32 304,216  
33 2,980  
34 34,678  
35 539,997  
36 295,424  
37 86,119;



## Anexo 4 : Métricas por distrito

Tabla de las métricas por Departamento-Provincia-Distrito

Índice	Departamento	Provincia	Distrito	Rendimiento	Region	Pobreza	Agua índice	Informalidad
1	Amazonas	Bagua	La Peca	13	Selva	34.55	66.055	85.35
2	Amazonas	Rodriguez de Mendoza	Cochamal	10	Selva	34.55	45.3	85.35
3	Amazonas	Bagua	Bagua	7	Selva	34.55	79.255	85.35
4	Apurímac	Abancay	Curahuasi	6	Sierra	34.55	45.3	88.04
5	Apurímac	Graú	Curpahuasi	5	Sierra	34.55	45.3	88.04
6	Apurímac	Andahuaylas	Huayana	4	Sierra	34.55	45.3	88.04
7	Ayacucho	Huamanga	Ayacucho	24	Sierra	34.55	79.255	87.10
8	Ayacucho	Huamanga	Carmen Alto	11	Sierra	34.55	79.255	87.10
9	Ayacucho	Huamanga	Pacaycasa	11	Sierra	34.55	79.255	87.10
10	Ayacucho	Lucanas	Chaviña	11	Sierra	34.55	66.055	87.10
11	Ayacucho	Huanta	Huanta	10	Sierra	34.55	79.255	87.10
12	Cajamarca	Cajabamba	Cachachi	21	Sierra	41.85	88.755	89.34
13	Cajamarca	Cajabamba	Cajabamba	19	Sierra	41.85	88.755	89.34
14	Cajamarca	Contumaza	San Benito	8	Sierra	41.85	45.3	89.34
15	Cuzco	Paruro	Accha	15	Sierra	23.1	45.3	81.61
16	Cuzco	Paruro	Ccapi	15	Sierra	23.1	45.3	81.61
17	Cuzco	La Convención	Pichari	7	Sierra	23.1	79.255	81.61
18	Huancavelica	Castrovirreyna	Arma	15	Sierra	34.55	96.015	91.41
19	Huancavelica	Churcampa	Churcampa	13	Sierra	34.55	45.3	91.41
20	Huancavelica	Tayacaja	Colcabamba	11	Sierra	34.55	45.3	91.41
21	Huánuco	Huamalies	Jacas Grande	10	Sierra	34.55	66.055	87.30
22	Huánuco	Pachitea	Chaglla	10	Sierra	34.55	88.755	87.30
23	Huánuco	Puerto Inca	Puerto Inca	8	Sierra	34.55	66.055	87.30
24	Junín	Satipo	Satipo	19	Sierra	23.1	66.055	83.48
25	Junín	Jauja	Molinos	7	Sierra	23.1	96.015	83.48
26	Loreto	Maynas	Indiana	12	Selva	34.55	96.015	81.80
27	Loreto	Loreto	Parinari	9	Sierra	34.55	96.015	81.80
28	Madre de Dios	Tahuamanu	Iñapari	9	Selva	3.1	88.755	76.16
29	Madre de Dios	Tambopata	Tambopata	8	Selva	3.1	79.255	76.16
30	Madre de Dios	Tahuamanu	Ibeia	8	Selva	3.1	88.755	76.16
31	Pasco	Oxapampa	Oxapampa	17	Sierra	34.55	96.015	80.90
32	San Martín	Mariscal Caceres	Huicungo	13	Sierra	23.1	96.015	84.63
33	San Martín	Lamas	Lamas	12	Selva	23.1	88.755	84.63
34	San Martín	Tocache	Tocache	12	Sierra	23.1	96.015	84.63
35	Ucayali	Coronel Portillo	Masisea	8	Selva	12.55	66.055	77.58
36	Ucayali	Atalaya	Sepahua	7	Selva	12.55	66.055	77.58
37	Ucayali	Coronel Portillo	Nueva Requena	7	Selva	12.55	79.255	77.58

## Anexo 5: Hectáreas libres por distrito

Tabla que muestra hectáreas libres por Departamento-Provincia-Distrito

Índice	Departamento	Provincia	Distrito	Porcentaje del departamento de tierra agrícola no trabajada (2018)	Hectareas libres
1	Amazonas	Bagua	La Peca	19%	343,980
2	Amazonas	Rodriguez de Mendoza	Cochamal	19%	4,004
3	Amazonas	Bagua	Bagua	19%	1,410
4	Apurímac	Abancay	Curahuasi	17%	15,110
5	Apurímac	Graú	Curpahuasi	17%	5,426
6	Apurímac	Andahuaylas	Huayana	17%	1,690
7	Ayacucho	Huamanga	Ayacucho	21%	1,792
8	Ayacucho	Huamanga	Carmen Alto	21%	406
9	Ayacucho	Huamanga	Pacaycasa	21%	8,781
10	Ayacucho	Lucanas	Chaviña	21%	7,815
11	Ayacucho	Huanta	Huanta	21%	7,458
12	Cajamarca	Cajabamba	Cachachi	17%	13,789
13	Cajamarca	Cajabamba	Cajabamba	17%	3,215
14	Cajamarca	Contumaza	San Benito	17%	8,233
15	Cuzco	Paruro	Accha	10%	2,497
16	Cuzco	Paruro	Ccapi	10%	3,415
17	Cuzco	La Convención	Pichari	10%	7,451
18	Huancavelica	Castrovirreyna	Arma	10%	3,153
19	Huancavelica	Churcampa	Churcampa	10%	1,463
20	Huancavelica	Tayacaja	Colcabamba	10%	6,187
21	Huánuco	Huamalies	Jacas Grande	29%	6,915
22	Huánuco	Pachitea	Chaglla	29%	19,391
23	Huánuco	Puerto Inca	Puerto Inca	29%	60,432
24	Junín	Satipo	Satipo	38%	27,875
25	Junín	Jauja	Molinos	38%	11,889
26	Loreto	Maynas	Indiana	46%	151,909
27	Loreto	Loreto	Parinari	46%	50,391
28	Madre de Dios	Tahuamanu	Iñapari	39%	585,367
29	Madre de Dios	Tambopata	Tambopata	39%	814,858
30	Madre de Dios	Tahuamanu	Ibeia	39%	100,453
31	Pasco	Oxapampa	Oxapampa	23%	9,819
32	San Martín	Mariscal Caceres	Huicungo	31%	304,216
33	San Martín	Lamas	Lamas	31%	2,980
34	San Martín	Tocache	Tocache	31%	34,678
35	Ucayali	Coronel Portillo	Masisea	38%	539,997
36	Ucayali	Atalaya	Sepahua	38%	295,424
37	Ucayali	Coronel Portillo	Nueva Requena	38%	86,119

## Anexo 6: Tabla de capacidad hídrica por distrito

Tabla que muestra la capacidad hídrica por Departamento-Provincia-Distrito

Índice	Departamento	Provincia	Distrito	Total disponible (hm <sup>3</sup> ) anual	Mensual	Hectareas abastecidas al año
1	Amazonas	Bagua	La Peca	585	44	46,838
2	Amazonas	Rodriguez de Mendoza	Cochamal	428	32	34,238
3	Amazonas	Bagua	Bagua	151	11	12,056
4	Apurímac	Abancay	Curahuasi	1,740	131	139,202
5	Apurímac	Graú	Curpahuasi	625	47	49,990
6	Apurímac	Andahuaylas	Huayana	195	15	15,571
7	Ayacucho	Huamanga	Ayacucho	171	13	13,710
8	Ayacucho	Huamanga	Carmen Alto	39	3	3,107
9	Ayacucho	Huamanga	Pacaycasa	840	63	67,190
10	Ayacucho	Lucanas	Chaviña	747	56	59,796
11	Ayacucho	Huanta	Huanta	713	53	57,063
12	Cajamarca	Cajabamba	Cachachi	1,638	123	131,004
13	Cajamarca	Cajabamba	Cajabamba	382	29	30,541
14	Cajamarca	Contumaza	San Benito	978	73	78,217
15	Cuzco	Paruro	Accha	492	37	39,349
16	Cuzco	Paruro	Ccapi	673	50	53,816
17	Cuzco	La Convención	Pichari	1,468	110	117,405
18	Huancavelica	Castrovirreyna	Arma	612	46	48,994
19	Huancavelica	Churcampa	Churcampa	284	21	22,729
20	Huancavelica	Tayacaja	Colcabamba	1,202	90	96,139
21	Huánuco	Huamalies	Jacas Grande	476	36	38,094
22	Huánuco	Pachitea	Chaglla	1,335	100	106,816
23	Huánuco	Puerto Inca	Puerto Inca	4,161	312	332,894
24	Junín	Satipo	Satipo	1,471	110	117,662
25	Junín	Jauja	Molinos	627	47	50,183
26	Loreto	Maynas	Indiana	6,627	497	530,123
27	Loreto	Loreto	Parinari	2,198	165	175,851
28	Madre de Dios	Tahuamanu	Iñapari	29,845	2,238	2,387,590
29	Madre de Dios	Tambopata	Tambopata	41,545	3,116	3,323,639
30	Madre de Dios	Tahuamanu	Ibeia	5,122	384	409,728
31	Pasco	Oxapampa	Oxapampa	843	63	67,479
32	San Martín	Mariscal Caceres	Huicungo	19,689	1,477	1,575,100
33	San Martín	Lamas	Lamas	193	14	15,431
34	San Martín	Tocache	Tocache	2,244	168	179,548
35	Ucayali	Coronel Portillo	Masissea	28,335	2,125	2,266,768
36	Ucayali	Atalaya	Sepahua	15,501	1,163	1,240,116
37	Ucayali	Coronel Portillo	Nueva Requena	4,519	339	361,506

## Anexo 7: Resultado de AMPL – activador binario mensual de distrito

Tabla de variable que active por mes

Activador mensual - distrital												
DISTRITOS	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
Amazonas, Bagua, La Peca	0	0	0	0	1	0	0	0	0	0	0	0
Amazonas, Rodriguez de Mendoza, Cochamal	0	0	0	0	0	0	0	0	0	0	0	0
Amazonas, Bagua, Bagua	0	0	0	0	0	0	0	0	0	0	0	0
Apurimac, Abancay, Curahuasi	0	0	0	0	0	0	0	0	0	0	0	0
Apurimac, Grau, Curpahuasi	0	0	0	0	0	0	0	0	0	0	0	0
Apurimac, Andahuaylas, Huayana	0	0	0	0	0	0	0	0	0	0	0	0
Ayacucho, Huamanga, Ayacucho	0	0	0	0	0	0	0	0	0	0	0	0
Ayacucho, Huamanga, Carmen Alto	0	0	0	0	1	0	0	0	0	0	0	0
Ayacucho, Huamanga, Pacaycasa	0	0	0	0	1	0	0	0	0	0	0	0
Ayacucho, Lucanas, Chaviña	0	0	0	1	1	0	0	0	0	0	0	0
Ayacucho, Huanta, Huanta	0	0	0	0	1	0	0	0	0	0	0	0
Cajamarca, Cajabamba, Cachachi	0	0	0	1	0	0	0	0	0	0	0	0
Cajamarca, Cajabamba, Cajabamba	0	0	0	0	0	0	1	1	0	0	0	0
Cajamarca, Contumaza, San Benito	0	0	0	0	0	0	0	0	0	0	0	0
Cuzco, Paruro, Accha	0	0	0	0	1	0	0	0	0	0	0	0
Cuzco, Paruro, Ccapi	0	0	0	0	1	0	0	0	0	0	0	0
Cuzco, La Convención, Pichari	0	0	0	0	0	0	0	0	0	0	0	0
Huancavelica, Castrovirreyna, Arma	0	0	0	0	1	0	0	0	0	0	0	0
Huancavelica, Churcampa, Churcampa	0	0	0	0	1	0	1	0	0	0	0	0
Huancavelica, Tayacaja, Colcabamba	0	0	0	1	1	0	0	0	0	0	0	0
Huánuco, Huamalíes, Jacas Grande	0	0	0	0	0	0	0	1	0	0	0	0
Huánuco, Pachitea, Chaglla	0	0	0	0	0	0	0	0	0	0	0	0
Huánuco, Puerto Inca, Puerto Inca	0	0	0	0	0	0	0	0	0	0	0	0
Junín, Satipo, Satipo	0	0	0	0	0	0	0	0	0	0	0	0
Junín, Jauja, Molinos	0	0	0	0	0	0	0	0	0	0	0	0
Loreto, Maynas, Indiana	0	0	0	0	0	0	0	0	0	0	0	0
Loreto, Loreto, Parinari	0	0	0	0	0	0	0	0	0	0	0	0
Madre de Dios, Tahuamanu, Iñapari	0	0	0	0	0	0	0	0	0	0	0	0
Madre de Dios, Tambopata, Tambopata	0	0	0	0	0	0	0	0	0	0	0	0
Madre de Dios, Tahuamanu, Ibeia	0	0	0	0	0	0	0	0	0	0	0	0
Pasco, Oxapampa, Oxapampa	0	0	0	0	1	0	0	0	0	0	0	0
San Martín, Mariscal Cáceres, Huicungo	0	0	0	0	0	0	0	0	0	0	0	0
San Martín, Lamas, Lamas	0	0	0	0	0	0	0	0	0	0	0	0
San Martín, Tocache, Tocache	0	0	0	0	0	0	0	0	0	0	0	0
Ucayali, Coronel Portillo, Masisea	0	0	0	0	0	0	0	0	0	0	0	0
Ucayali, Atalaya, Sepahua	0	0	0	0	0	0	0	0	0	0	0	0
Ucayali, Coronel Portillo, Nueva Requena	0	0	0	0	0	0	0	0	0	0	0	0

## Anexo 8: Resultado de AMPL – activador binario anual de distrito

Tabla de la variable que activaba los distritos de manera anual.


Activador anual - distrital	
DISTRITOS	Actividad
Amazonas,Bagua,La Peca	1
Amazonas,Rodriguez de Mendoza,Cochamal	0
Amazonas,Bagua,Bagua	0
Apurímac,Abancay,Curahuasi	0
Apurímac,Grau,Curpahuasi	0
Apurímac,Andahuaylas,Huayana	0
Ayacucho,Huamanga,Ayacucho	0
Ayacucho,Huamanga,Carmen Alto	1
Ayacucho,Huamanga,Pacaycasa	1
Ayacucho,Lucanas,Chaviña	1
Ayacucho,Huanta,Huanta	1
Cajamarca,Cajabamba,Cachachi	1
Cajamarca,Cajabamba,Cajabamba	1
Cajamarca,Contumaza,San Benito	0
Cuzco,Paruro,Accha	1
Cuzco,Paruro,Ccapi	1
Cuzco,La Convención,Pichari	0
Huancavelica,Castrovirreyna,Arma	1
Huancavelica,Churcampa,Churcampa	1
Huancavelica,Tayacaja,Colcabamba	1
Huánuco,Huamalies,Jacas Grande	1
Huánuco,Pachitea,Chaglla	0
Huánuco,Puerto Inca,Puerto Inca	0
Junín ,Satipo,Satipo	0
Junín ,Jauja,Molinos	0
Loreto,Maynas,Indiana	0
Loreto,Loreto,Parinari	0
Madre de Dios,Tahuamanu,Iñapari	0
Madre de Dios,Tambopata,Tambopata	0
Madre de Dios,Tahuamanu,Ibeia	0
Pasco,Oxampampa,Oxapampa	1
San Martín,Mariscal Caceres,Huicungo	0
San Martín,Lamas,Lamas	0
San Martín,Tocache,Tocache	0
Ucayali,Coronel Portillo,Masisea	0
Ucayali,Atalaya,Sepahua	0
Ucayali,Coronel Portillo,Nueva Requena	0



## Anexo 9: Resultado de AMPL toneladas por distrito-meses

Tabla que muestra la capacidad hídrica por Departamento-Provincia-Distrito

Cantidad de toneladas a producir												
DISTRITOS	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
Amazonas, Bagua, La Peca	0	0	0	0	8898	0	0	0	0	0	0	0
Amazonas, Rodríguez de Mendoza, Cochamal	0	0	0	0	0	0	0	0	0	0	0	0
Amazonas, Bagua, Bagua	0	0	0	0	0	0	0	0	0	0	0	0
Apurímac, Abancay, Curahuasi	0	0	0	0	0	0	0	0	0	0	0	0
Apurímac, Grau, Curpahuasi	0	0	0	0	0	0	0	0	0	0	0	0
Apurímac, Andahuaylas, Huayana	0	0	0	0	0	0	0	0	0	0	0	0
Ayacucho, Huamanga, Ayacucho	0	0	0	0	0	0	0	0	0	0	0	0
Ayacucho, Huamanga, Carmen Alto	0	0	0	0	550	0	0	0	0	0	0	0
Ayacucho, Huamanga, Pacaycasa	0	0	0	0	550	0	0	0	0	0	0	0
Ayacucho, Lucanas, Chaviña	0	0	0	618	550	0	0	0	0	0	0	0
Ayacucho, Huanta, Huanta	0	0	0	0	500	0	0	0	0	0	0	0
Cajamarca, Cajabamba, Cachachi	0	0	0	1050	0	0	0	0	0	0	0	0
Cajamarca, Cajabamba, Cajabamba	0	0	0	0	0	0	4638	4220	0	0	0	0
Cajamarca, Contumaza, San Benito	0	0	0	0	0	0	0	0	0	0	0	0
Cuzco, Paruro, Accha	0	0	0	0	750	0	0	0	0	0	0	0
Cuzco, Paruro, Ccapi	0	0	0	0	750	0	0	0	0	0	0	0
Cuzco, La Convención, Pichari	0	0	0	0	0	0	0	0	0	0	0	0
Huancavelica, Castrovirreyña, Arma	0	0	0	0	750	0	0	0	0	0	0	0
Huancavelica, Churcampá, Churcampá	0	0	0	0	650	0	650	0	0	0	0	0
Huancavelica, Tayacaja, Colcabamba	0	0	0	550	550	0	0	0	0	0	0	0
Huánuco, Huamallas, Jacas Grande	0	0	0	0	0	0	0	500	0	0	0	0
Huánuco, Pachitea, Chaglla	0	0	0	0	0	0	0	0	0	0	0	0
Huánuco, Puerto Inca, Puerto Inca	0	0	0	0	0	0	0	0	0	0	0	0
Junín, Satipo, Satipo	0	0	0	0	0	0	0	0	0	0	0	0
Junín, Jauja, Molinos	0	0	0	0	0	0	0	0	0	0	0	0
Loreto, Maynas, Indiana	0	0	0	0	0	0	0	0	0	0	0	0
Loreto, Loreto, Parinari	0	0	0	0	0	0	0	0	0	0	0	0
Madre de Dios, Tahuamanu, Iñapari	0	0	0	0	0	0	0	0	0	0	0	0
Madre de Dios, Tambopata, Tambopata	0	0	0	0	0	0	0	0	0	0	0	0
Madre de Dios, Tahuamanu, Ibeja	0	0	0	0	0	0	0	0	0	0	0	0
Pasco, Oxapampa, Oxapampa	0	0	0	0	850	0	0	0	0	0	0	0
San Martín, Mariscal Cáceres, Huicungo	0	0	0	0	0	0	0	0	0	0	0	0
San Martín, Lamas, Lamas	0	0	0	0	0	0	0	0	0	0	0	0
San Martín, Tocache, Tocache	0	0	0	0	0	0	0	0	0	0	0	0
Ucayali, Coronel Portillo, Masisea	0	0	0	0	0	0	0	0	0	0	0	0
Ucayali, Atalaya, Sepahua	0	0	0	0	0	0	0	0	0	0	0	0
Ucayali, Coronel Portillo, Nueva Requena	0	0	0	0	0	0	0	0	0	0	0	0



**Anexo 10: Flujo de kilos cosechados escenario probable**

Kilos por hectárea																		
-	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
	251	1170	2297	4177	7518	9189	10860	15663	16290	16290	16290	15663	14410	14410	9189	8354	8354	



## Anexo 11: Flujo económico probable

Flujo de económico para una hectárea																			
Descripción	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10	Año 11	Año 12	Año 13	Año 14	Año 15	Año 16	Año 17	Año 18
Kilos cosechados	-	-	250.61	1,169.53	2,297.30	4,176.90	7,518.42	9,189.18	10,859.94	15,663.38	16,289.91	16,289.91	16,289.91	15,663.38	14,410.31	14,410.31	9,189.18	8,353.80	8,353.80
<b>Ingreso</b>																			
Monto en soles exportación (90%)	-	-	1,522.48	7,104.91	13,956.07	25,374.67	45,674.40	55,824.27	65,974.14	95,155.00	98,961.20	98,961.20	98,961.20	95,155.00	87,542.60	87,542.60	55,824.27	50,749.34	50,749.34
Monto en soles Perú (10%)	-	-	137.84	643.24	1,263.51	2,297.30	4,135.13	5,054.05	5,972.97	8,614.86	8,959.45	8,959.45	8,959.45	8,614.86	7,925.67	7,925.67	5,054.05	4,594.59	4,594.59
<b>Total de ingresos</b>	-	-	1,660.32	7,748.15	15,219.58	27,671.96	49,809.53	60,878.32	71,947.10	103,769.86	107,920.65	107,920.65	107,920.65	103,769.86	95,468.27	95,468.27	60,878.32	55,343.93	55,343.93
<b>Egresos</b>																			
Terreno	26,000.00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
<b>Costos Directos</b>																			
Semillas e injertos (Var. Hass)	1,785.00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Agua	171.00	138.00	152.00	184.00	212.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00
Mano de obra	520.00	618.00	679.00	641.00	738.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00
Insumo agrícolas (cultivo)	1,161.00	1,372.00	1,509.00	1,834.00	2,109.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00
Mano de obra (cosecha)	-	-	15.00	73.00	147.00	166.00	166.00	221.00	249.00	246.00	369.00	387.00	461.00	461.00	461.00	461.00	461.00	461.00	461.00
<b>Costos indirectos</b>																			
Cargas diversas de gestión	452.00	505.00	539.00	984.00	9,595.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00
Combustible	227.00	2,687.00	295.00	295.00	246.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00
Servicios prestados por terceros	107.00	127.00	140.00	137.00	100.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00
Combustible (cosecha)	-	-	-	24.00	49.00	61.00	61.00	73.00	86.00	92.00	120.00	129.00	153.00	153.00	153.00	153.00	153.00	153.00	153.00
Transporte a punto de encuentro	-	-	200.00	400.00	500.00	500.00	500.00	500.00	-	-	400.00	400.00	400.00	400.00	-	-	-	-	-
Servicios de transporte a Lima	-	-	162.90	760.20	1,493.24	2,714.99	4,886.97	5,972.97	6,500.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	6,500.00	6,500.00	6,500.00
Servicio de maquila	-	-	593.00	276.00	543.00	988.00	1,482.00	1,812.00	2,570.00	3,707.00	3,855.00	3,855.00	3,855.00	3,707.00	3,707.00	3,707.00	3,707.00	3,707.00	3,707.00
<b>Total de egresos</b>	30,423.00	5,447.00	4,284.90	5,608.20	15,732.24	9,915.99	12,581.97	14,064.97	14,891.00	18,531.00	19,230.00	19,257.00	19,355.00	19,207.00	18,807.00	18,807.00	16,307.00	16,307.00	16,307.00
Impuesto a la renta (IR)	-	-	-	320.99	-	2,663.40	5,584.13	7,022.00	8,558.42	12,785.83	13,303.60	13,299.55	13,284.85	12,684.43	11,499.19	11,499.19	6,685.70	5,855.54	5,855.54
<b>Flujo económico</b>	<b>30,423.00</b>	<b>5,447.00</b>	<b>2,624.58</b>	<b>1,818.96</b>	<b>512.66</b>	<b>15,092.58</b>	<b>31,643.43</b>	<b>39,791.35</b>	<b>48,497.69</b>	<b>72,453.03</b>	<b>75,387.06</b>	<b>75,364.11</b>	<b>75,280.81</b>	<b>71,878.43</b>	<b>65,162.08</b>	<b>65,162.08</b>	<b>37,885.62</b>	<b>33,181.39</b>	<b>33,181.39</b>
<b>Flujo acumulado</b>	30,423.00	35,870.00	38,494.58	36,354.63	36,867.29	19,111.31	18,116.25	64,929.60	121,985.70	207,224.56	295,915.21	384,578.87	473,144.52	557,707.38	634,368.65	711,029.92	755,601.24	794,638.16	833,675.09

## Anexo 12: Flujo económico pesimista

Flujo de económico para una hectárea																			
Descripción	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10	Año 11	Año 12	Año 13	Año 14	Año 15	Año 16	Año 17	Año 18
Kilos cosechados	-	-	238.08	1,111.06	2,182.43	3,968.06	7,142.50	8,729.72	10,316.94	14,880.21	15,475.41	15,475.41	15,475.41	14,880.21	13,689.79	13,689.79	8,729.72	7,936.11	7,936.11
<b>Ingreso</b>																			
Io																			
Monto en soles exportación (90%)	-	-	1,446.36	6,749.66	13,258.26	24,105.93	43,390.68	53,033.06	62,675.43	90,397.25	94,013.14	94,013.14	94,013.14	90,397.25	83,165.47	83,165.47	53,033.06	48,211.87	48,211.87
Monto en soles Perú (10%)	-	-	130.95	611.08	1,200.34	2,182.43	3,928.37	4,801.35	5,674.32	8,184.11	8,511.48	8,511.48	8,511.48	8,184.11	7,529.38	7,529.38	4,801.35	4,364.86	4,364.86
Total de ingresos	-	-	1,577.30	7,360.74	14,458.60	26,288.36	47,319.06	57,834.40	68,349.75	98,581.37	102,524.62	102,524.62	102,524.62	98,581.37	90,694.86	90,694.86	57,834.40	52,576.73	52,576.73
<b>Egresos</b>																			
Terreno	26,000.00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
<b>Costos Directos</b>																			
Semillas e injertos (Var. Hass)	1,785.00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Agua	171.00	138.00	152.00	184.00	212.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00
Mano de obra	520.00	618.00	679.00	641.00	738.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00
Insumo agrícolas (cultivo)	1,161.00	1,372.00	1,509.00	1,834.00	2,109.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00
Mano de obra (cosecha)	-	-	15.00	73.00	147.00	166.00	166.00	221.00	249.00	246.00	369.00	387.00	461.00	461.00	461.00	461.00	461.00	461.00	461.00
<b>Costos indirectos</b>																			
Cargas diversas de gestión	452.00	505.00	539.00	984.00	9,595.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00
Combustible	227.00	2,687.00	295.00	295.00	246.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00
Servicios prestados por terceros	107.00	127.00	140.00	137.00	100.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00
Combustible (cosecha)	-	-	-	24.00	49.00	61.00	61.00	73.00	86.00	92.00	120.00	129.00	153.00	153.00	153.00	153.00	153.00	153.00	153.00
Transporte a punto de encuentro			200.00	400.00	500.00	500.00	500.00	500.00			400.00	400.00	400.00	400.00					
Servicios de transporte	-	-	154.75	722.19	1,418.58	2,579.24	4,642.62	5,674.32	6,500.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	6,500.00	6,500.00	6,500.00
Servicio de maquila	-	-	593.00	276.00	543.00	988.00	1,482.00	1,812.00	2,570.00	3,707.00	3,855.00	3,855.00	3,855.00	3,707.00	3,707.00	3,707.00	3,707.00	3,707.00	3,707.00
Total de egresos	30,423.00	5,447.00	4,276.75	5,570.19	15,657.58	9,780.24	12,337.62	13,766.32	14,891.00	18,531.00	19,230.00	19,257.00	19,355.00	19,207.00	18,807.00	18,807.00	16,307.00	16,307.00	16,307.00
Impuesto a la renta (IR)		-	-	268.58	-	2,476.22	5,247.21	6,610.21	8,018.81	12,007.55	12,494.19	12,490.14	12,475.44	11,906.15	10,783.18	10,783.18	6,229.11	5,440.46	5,440.46
<b>Flujo económico</b>	<b>30,423.00</b>	<b>5,447.00</b>	<b>2,699.45</b>	<b>1,521.97</b>	<b>1,198.98</b>	<b>14,031.91</b>	<b>29,734.22</b>	<b>37,457.87</b>	<b>45,439.94</b>	<b>68,042.81</b>	<b>70,800.43</b>	<b>70,777.48</b>	<b>70,694.18</b>	<b>67,468.21</b>	<b>61,104.68</b>	<b>61,104.68</b>	<b>35,298.29</b>	<b>30,829.27</b>	<b>30,829.27</b>

<b>Flujo acumulado</b>	-	-	-	-	-	-	-	57,579.77	111,038.51	191,088.88	274,383.50	357,651.12	440,820.74	520,195.11	592,082.97	663,970.83	705,498.23	741,767.96	778,037.68
------------------------	---	---	---	---	---	---	---	-----------	------------	------------	------------	------------	------------	------------	------------	------------	------------	------------	------------

## Anexo 13: Flujo económico optimista

Flujo de económico para una hectárea																			
Descripción	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10	Año 11	Año 12	Año 13	Año 14	Año 15	Año 16	Año 17	Año 18
Kilos cosechados	-	-	263.14	1,228.01	2,412.16	4,385.75	7,894.34	9,648.64	11,402.94	16,446.54	17,104.41	17,104.41	17,104.41	16,446.54	15,130.82	15,130.82	9,648.64	8,771.49	8,771.49
<b>Ingreso</b>																			
Io																			
Monto en soles exportación (90%)	-	-	1,598.60	7,460.15	14,653.87	26,643.40	47,958.12	58,615.48	69,272.84	99,912.75	103,909.26	103,909.26	103,909.26	99,912.75	91,919.73	91,919.73	58,615.48	53,286.80	53,286.80
Monto en soles Perú (10%)	-	-	144.73	675.40	1,326.69	2,412.16	4,341.89	5,306.75	6,271.62	9,045.60	9,407.42	9,407.42	9,407.42	9,045.60	8,321.95	8,321.95	5,306.75	4,824.32	4,824.32
<b>Total de ingresos</b>	-	-	1,743.33	8,135.56	15,980.56	29,055.56	52,300.01	63,922.23	75,544.46	108,958.35	113,316.69	113,316.69	113,316.69	108,958.35	100,241.68	100,241.68	63,922.23	58,111.12	58,111.12
<b>Egresos</b>																			
Terreno	26,000.00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
<b>Costos Directos</b>																			
Semillas e injertos (Var. Hass)	1,785.00	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
Agua	171.00	138.00	152.00	184.00	212.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00	309.00
Mano de obra	520.00	618.00	679.00	641.00	738.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00	1,000.00
Insumo agrícolas (cultivo)	1,161.00	1,372.00	1,509.00	1,834.00	2,109.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00	2,404.00
Mano de obra (cosecha)	-	-	15.00	73.00	147.00	166.00	166.00	221.00	249.00	246.00	369.00	387.00	461.00	461.00	461.00	461.00	461.00	461.00	461.00
<b>Costos indirectos</b>																			
Cargas diversas de gestión	452.00	505.00	539.00	984.00	9,595.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00	1,303.00
Combustible	227.00	2,687.00	295.00	295.00	246.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00	334.00
Servicios prestados por terceros	107.00	127.00	140.00	137.00	100.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00	136.00
Combustible (cosecha)	-	-	-	24.00	49.00	61.00	61.00	73.00	86.00	92.00	120.00	129.00	153.00	153.00	153.00	153.00	153.00	153.00	153.00
Transporte a punto de encuentro	-	-	200.00	400.00	500.00	500.00	500.00	-	400.00	400.00	400.00	400.00	400.00	400.00					
Servicios de transporte	-	-	171.04	798.21	1,567.90	2,850.73	5,131.32	6,500.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	9,000.00	6,500.00	6,500.00	6,500.00
Servicio de maquila	-	-	593.00	276.00	543.00	988.00	1,482.00	1,812.00	2,570.00	3,707.00	3,855.00	3,855.00	3,855.00	3,707.00	3,707.00	3,707.00	3,707.00	3,707.00	3,707.00
<b>Total de egresos</b>	30,423.00	5,447.00	4,293.04	5,646.21	15,806.90	10,051.73	12,826.32	14,092.00	17,391.00	18,931.00	19,230.00	19,257.00	19,355.00	19,207.00	18,807.00	18,807.00	16,307.00	16,307.00	16,307.00
Impuesto a la renta (IR)	-	-	-	373.40	26.05	2,850.57	5,921.05	7,474.54	8,723.02	13,504.05	14,113.00	14,108.95	14,094.25	13,462.70	12,215.20	12,215.20	7,142.29	6,270.62	6,270.62
<b>Flujo económico</b>	<b>-</b>	<b>-</b>	<b>-</b>	<b>2,115.95</b>	<b>147.61</b>	<b>16,153.25</b>	<b>33,552.63</b>	<b>42,355.70</b>	<b>49,430.44</b>	<b>76,523.25</b>	<b>79,973.68</b>	<b>79,950.73</b>	<b>79,867.43</b>	<b>76,288.65</b>	<b>69,219.48</b>	<b>69,219.48</b>	<b>40,472.95</b>	<b>35,533.50</b>	<b>35,533.50</b>

Flujo acumulado	-	-	-	-	-	-	22,720.81	72,551.04	130,704.50	220,731.85	314,818.54	408,878.23	502,839.91	592,591.26	674,025.95	755,460.63	803,075.87	844,879.99	886,684.11
-----------------	---	---	---	---	---	---	-----------	-----------	------------	------------	------------	------------	------------	------------	------------	------------	------------	------------	------------

### Anexo 14: Flujo de crédito bancario probable

Flujo de financiamiento neto						
Descripción	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5
Préstamo	25,332.71					
Amortizaciones		- 5,066.54	- 5,066.54	- 5,066.54	- 5,066.54	- 5,066.54
Interes		- 2,753.67	- 2,202.93	- 1,652.20	- 1,101.47	- 550.73
Monto Total	25,332.71	- 7,820.21	- 7,269.47	- 6,718.74	- 6,168.01	- 5,617.27
Escudo tributario		812.33	649.86	487.40	324.93	162.47
<b>Flujo financiamiento neto</b>	25,332.71	- 7,007.88	- 6,619.61	- 6,231.34	- 5,843.07	- 5,454.81

### Anexo 15: Flujo de crédito bancario pesimista

Flujo de financiamiento Neto						
Descripción	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5
Préstamo	25,385.12					
Amortizaciones		- 5,077.02	- 5,077.02	- 5,077.02	- 5,077.02	- 5,077.02
Interes		- 2,759.36	- 2,207.49	- 1,655.62	- 1,103.74	- 551.87
Monto Total	25,385.12	- 7,836.39	- 7,284.51	- 6,732.64	- 6,180.77	- 5,628.90
Escudo tributario		814.01	651.21	488.41	325.60	162.80
<b>Flujo financiamiento neto</b>	25,385.12	- 7,022.37	- 6,633.30	- 6,244.23	- 5,855.16	- 5,466.09

## Anexo 16: Flujo de crédito bancario optimista

Flujo de financiamiento Neto						
Descripción	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5
Préstamo	25,280.30					
Amortizaciones		- 5,056.06	- 5,056.06	- 5,056.06	- 5,056.06	- 5,056.06
Interes		- 2,747.97	- 2,198.37	- 1,648.78	- 1,099.19	- 549.59
Monto Total	25,280.30	- 7,804.03	- 7,254.43	- 6,704.84	- 6,155.25	- 5,605.65
Escudo tributario		810.65	648.52	486.39	324.26	162.13
<b>Flujo financiamiento neto</b>	25,280.30	- 6,993.38	- 6,605.91	- 6,218.45	- 5,830.99	- 5,443.52



## Anexo 17: Flujo financiero probable

Flujo Financiero																		
Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10	Año 11	Año 12	Año 13	Año 14	Año 15	Año 16	Año 17	Año 18
-	-	-	-	-	9,637.77	31,643.43	39,791.35	48,497.69	72,453.03	75,387.06	75,364.11	75,280.81	71,878.43	65,162.08	65,162.08	37,885.62	33,181.39	33,181.39
2,785.29	12,454.88	9,244.19	4,412.38	6,355.74														

## Anexo 18: Flujo financiero pesimista

Flujo Financiero																		
Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10	Año 11	Año 12	Año 13	Año 14	Año 15	Año 16	Año 17	Año 18
-	-	-	-	-	8,565.82	29,734.22	37,457.87	45,439.94	68,042.81	70,800.43	70,777.48	70,694.18	67,468.21	61,104.68	61,104.68	35,298.29	30,829.27	30,829.27
2,732.88	12,469.37	9,332.76	4,722.26	7,054.14														

## Anexo 19: Flujo financiero optimista

Flujo Financiero																		
Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10	Año 11	Año 12	Año 13	Año 14	Año 15	Año 16	Año 17	Año 18
-	-	-	-	-	10,709.73	33,552.63	42,355.70	49,430.44	76,523.25	79,973.68	79,950.73	79,867.43	76,288.65	69,219.48	69,219.48	40,472.95	35,533.50	35,533.50
2,837.70	12,440.38	9,155.62	4,102.50	5,683.38														





## Anexo 20 : Script de PCA

Script para el análisis de principales componentes

```
library("ggplot2")
```

```
library("dplyr")
```

```
library("readxl")
```

```
library("corrplot")
```

```
library("ggridges")
```

```
library("FactoMineR")
```

```
library("factoextra")
```

```
library("forcats")
```

```
#####  
##### TRATAMIENTO DE DATOS #####  
#####
```

```
datos <- read_excel("D:/OneDrive/docs tesis/Info tesis.xlsx")
```

```
datos <- datos %>% select(-Fuente_Agua, -Terreno, -Pobreza, -Agua, -Proporcion, -  
Produccion_total)
```

```
datos$Mes_selecto <- as.integer(datos$Mes_selecto)
```

```
datos$Mes <-
```

```
factor(datos$Mes, levels=c("Enero", "Febrero", "Marzo", "Abril", "Mayo", "Junio", "Julio", "Agosto", "  
Septiembre", "Octubre", "Noviembre", "Diciembre"))
```

```
datos_num <- datos %>% select(Departamento, Provincia, Distrito, Temperatura_media, Tempera  
tura_min, Temperatura_max, Precipitacion, Altura, Viento, Energia_solar, Proporcion_de_nubes,  
Rendimiento) %>% arrange(Departamento, Distrito)
```

```
datos_num$Energia_solar <- as.numeric(datos_num$Energia_solar)
```

Excel<-

```
datos_num%>%group_by(Departamento,Distrito)%>%summarize(Temperatura_media_pro  
medio=mean(Temperatura_media),Temperatura_sd=sd(Temperatura_media),
```

```
Temperatura_cv=sd(Temperatura_media)/mean(Temperatura_media)*100,Precipitacion_pro  
m=mean(Precipitacion),Precipitacion_sd=sd(Precipitacion),Precipitacion_cv=sd(Precipitacion  
)/mean(Precipitacion)*100,altura=mean(Altura),viento_prom=mean(Viento),viento_sd=sd(Vie  
nto),viento_cv=sd(Viento)/mean(Viento)*100,Energia_solar_prom=mean(Energia_solar),
```

```
Energia_solar_sd=sd(Energia_solar),Energia_cv=sd(Energia_solar)/mean(Energia_solar)*10  
0,
```

```
Proporcion_de_nubes_prom=mean(Proporcion_de_nubes),Proporcion_nubes_cv=sd(Propor  
cion_de_nubes)/mean(Proporcion_de_nubes)*100,
```

```
Proporcion_de_nubes_sd=sd(Proporcion_de_nubes),Rendimiento=mean(Rendimiento))
```

```
Excel<-as.data.frame(Excel)
```

```
rownames(Excel) <- paste0(Excel$Departamento,"-",Excel$Distrito)
```

```
#####  
##### PCA #####  
#####
```

#Análisis

```
res.pca<-PCA(Excel[,-c(1,2,19)],scale.unit = TRUE,graph=FALSE)
```

```
eig.val <- get_eigenvalue(res.pca)
```

```
fviz_eig(res.pca, addlabels = TRUE, ylim = c(0, 50))
```

```
fviz_contrib(res.pca,choice="var",axes=1:2,top = 20)
```

```
var <- get_pca_var(res.pca)
```

```
ind <- get_pca_ind(res.pca)
```

#Ver las coordenadas en las dimensiones

```
ind$coord
```

#Gráfico para usar el método del codo

```
fviz_nbclust(ind$coord, kmeans, method = "wss") +  
  geom_vline(xintercept = 7, linetype = 2)
```

#Visualizar la relación entre las variables

```
fviz_pca_var(res.pca, col.var = "cos2",  
  gradient.cols = c("#00AFBB", "#E7B800", "#FC4E07"),  
  repel = TRUE)  
fviz_pca_ind(res.pca, col.ind = Excel[,19], gradient.cols = c("#00AFBB", "#E7B800",  
  "#FC4E07"), repel = TRUE # Avoid text overlapping (slow if many points))
```

###Dendogramas

```
res.hcpc <- HCPC(res.pca, nb.clust=7, graph = FALSE)  
fviz_dend(res.hcpc,  
  cex = 0.7, # Label size  
  palette = "jco", # Color palette see ?ggpubr::ggpar  
  rect = TRUE, rect_fill = TRUE, # Add rectangle around groups  
  rect_border = "jco", # Rectangle color  
  labels_track_height = 0.8 # Augment the room for labels  
)
```

## Anexo 21: Script de series de tiempo

Script para el análisis de series de tiempo

```
library("astsa")
```

```
library("readxl")
```

```
library("ggplot2")
```

```
library("plotly")
```

```
library("dplyr")
```

```
library("forecast")
```

```
library("TSA")
```

```
library("tidyr")
```

```
library("tseries")
```

```
#####  
##### IMPORTACIONES #####  
#####
```

```
#China es hasta 2019/12, EEUU y PB hasta 2020/07 al igual que la data peruana
```

```
EEUU_imp <- read_excel("D:/OneDrive/docs tesis/trademap.xlsx",sheet="Data.EEUU")
```

```
China_imp<- read_excel("D:/OneDrive/docs tesis/trademap.xlsx",sheet="Data.China")
```

```
Paises_bajos_imp<- read_excel("D:/OneDrive/docs  
tesis/trademap.xlsx",sheet="Data.PaisesBajos")
```

```
#####  
##### TRATAMIENTO DE DATOS #####  
#####
```

### #Años

```
EEUU_imp$Año<-as.numeric(EEUU_imp$Año)
China_imp$Año<-as.numeric(China_imp$Año)
Paises_bajos_imp$Año<-as.numeric(Paises_bajos_imp$Año)
```

### #Años.mes

```
EEUU_imp$Año.Mes<-as.numeric(EEUU_imp$Año.Mes)
China_imp$Año.Mes<-as.numeric(China_imp$Año.Mes)
Paises_bajos_imp$Año.Mes<-as.numeric(Paises_bajos_imp$Año.Mes)
```

### #Meses EEUU

```
EEUU_imp$Mes[EEUU_imp$Mes=="01"]<-"Enero"
EEUU_imp$Mes[EEUU_imp$Mes=="02"]<-"Febrero"
EEUU_imp$Mes[EEUU_imp$Mes=="03"]<-"Marzo"
EEUU_imp$Mes[EEUU_imp$Mes=="04"]<-"Abril"
EEUU_imp$Mes[EEUU_imp$Mes=="05"]<-"Mayo"
EEUU_imp$Mes[EEUU_imp$Mes=="06"]<-"Junio"
EEUU_imp$Mes[EEUU_imp$Mes=="07"]<-"Julio"
EEUU_imp$Mes[EEUU_imp$Mes=="08"]<-"Agosto"
EEUU_imp$Mes[EEUU_imp$Mes=="09"]<-"Septiembre"
EEUU_imp$Mes[EEUU_imp$Mes=="10"]<-"Octubre"
EEUU_imp$Mes[EEUU_imp$Mes=="11"]<-"Noviembre"
EEUU_imp$Mes[EEUU_imp$Mes=="12"]<-"Diciembre"
```

```
EEUU_imp$Mes<-
factor(EEUU_imp$Mes,levels=c("Enero","Febrero","Marzo","Abril","Mayo","Junio","Julio","Agosto","Septiembre","Octubre","Noviembre","Diciembre"))
```

### #Meses China

```
China_imp$Mes[China_imp$Mes=="01"]<-"Enero"
```

```
China_imp$Mes[China_imp$Mes=="02"]<-"Febrero"
```

```
China_imp$Mes[China_imp$Mes=="03"]<-"Marzo"
```

```
China_imp$Mes[China_imp$Mes=="04"]<-"Abril"
```

```
China_imp$Mes[China_imp$Mes=="05"]<-"Mayo"
```

```
China_imp$Mes[China_imp$Mes=="06"]<-"Junio"
```

```
China_imp$Mes[China_imp$Mes=="07"]<-"Julio"
```

```
China_imp$Mes[China_imp$Mes=="08"]<-"Agosto"
```

```
China_imp$Mes[China_imp$Mes=="09"]<-"Septiembre"
```

```
China_imp$Mes[China_imp$Mes=="10"]<-"Octubre"
```

```
China_imp$Mes[China_imp$Mes=="11"]<-"Noviembre"
```

```
China_imp$Mes[China_imp$Mes=="12"]<-"Diciembre"
```

```
China_imp$Mes<-
```

```
factor(China_imp$Mes,levels=c("Enero","Febrero","Marzo","Abril","Mayo","Junio","Julio","Ago  
sto","Septiembre","Octubre","Noviembre","Diciembre"))
```

### #Meses Paises bajos

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="01"]<-"Enero"
```

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="02"]<-"Febrero"
```

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="03"]<-"Marzo"
```

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="04"]<-"Abril"
```

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="05"]<-"Mayo"
```

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="06"]<-"Junio"
```

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="07"]<-"Julio"
```

```
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="08"]<-"Agosto"
```

```

Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="09"]<-"Septiembre"
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="10"]<-"Octubre"
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="11"]<-"Noviembre"
Paises_bajos_imp$Mes[Paises_bajos_imp$Mes=="12"]<-"Diciembre"

```

```

Paises_bajos_imp$Mes<-
factor(Paises_bajos_imp$Mes,levels=c("Enero","Febrero","Marzo","Abril","Mayo","Junio","Julio","Agosto","Septiembre","Octubre","Noviembre","Diciembre"))

```

```

#####
##### ARIMA #####
#####

```

```

#####
##### EEUU #####
#####

```

```
#ETL
```

```
EEUU_imp<-EEUU_imp%>%arrange(Año.Mes)
```

```
EEUU_imp<-EEUU_imp[,c(6,7,8,9)]
```

```
dates <- seq(as.Date("2007-12-01"), length = 152, by = "months")
```

```
EEUU_imp<-cbind(EEUU_imp,dates)
```

```
EEUU_imp<-EEUU_imp[,c(5,1,2,3,4)]
```

```
EEUU<-ts(EEUU_imp[,c(2,3,4,5)],start=c(2007,12),frequency = 12)
```

```
#Gráfico del comportamiento de las imputaciones por país exportador durante los años
```



```

autoplots(window(EEUU,start=2015))+ theme_classic()+

  theme(axis.text = element_text(size = 12),axis.title =
element_text(size=14),legend.title=element_text(size=14),legend.text=element_text(size=12)
,title=element_text(size=18))+

  ylab("Toneladas de palta")+xlab("Meses")+labs(title = "Importaciones de Estados
Unidos",color='Países')

```

#Gráfico estacional por meses

```

ggplotly(ggseasonplot(EEUU[,4]))

ggseasonplot(EEUU[,4])+ theme_classic()+ theme(axis.text = element_text(size =
12),axis.title =
element_text(size=14),legend.title=element_text(size=14),legend.text=element_text(size=12)
,title=element_text(size=18))+ ylab("Toneladas de palta")+xlab("Meses")+labs(title =
"Importaciones mensuales de Estados Unidos",color='Años')

```

#Peru tiene subida de producción cuando México cae, potencial mercado, buen dato

#Separación de los exportadores

```
EEUU_Mexico<-EEUU[,1]
```

```
EEUU_Chile<-EEUU[,2]
```

```
EEUU_Rep<-EEUU[,3]
```

```
EEUU_Peru<-EEUU[,4]
```

```

#####
#####                Mexico                #####
#####
#####

```

#Hasta el 7mo mes, Julio

#Gráficos del comportamiento

```

autoplot(EEUU_Mexico)

#Post-Tranformaciones realizadas
autoplot(diff(log(EEUU_Mexico)))

#Gráfico estacional por mes del exportador México a EEUU

ggplotly(ggseasonplot(EEUU_Mexico)) ## tiene un crecimiento pero baja por los meses de
mayo a agosto y sube

## En de Octubre a Marzo exporta más

# Ljung Box test es para saber si es un ruido blanco
Box.test(diff(log(EEUU_Mexico)),lag=12,type="Ljung")

# p-value < 2.2e-16 , no es un ruido blanco
# Se necesita uan diferenciación normal
EEUU_Mexico%>%diff(lag=12)%>%ndiffs()

# ¿Su estacionalidad?
acf2(diff(diff(log(EEUU_Mexico)),lag=12))
acfpl<-acf(diff(log(EEUU_Mexico)),plot=FALSE)
acfpl$lag <- acfpl$lag * 12
plot(acfpl, xlab="Lag (months)")

pacf(diff(diff(log(EEUU_Mexico)),lag=12))
acfpl2$lag <- acfpl$lag * 12
plot(acfpl2, xlab="Lag (months)")

## su estacionalidad es de 12

#Modelamiento
fit1<-auto.arima(EEUU_Mexico,lambda = BoxCox.lambda(EEUU_Mexico),stepwise =
FALSE,max.order=50,approximation = FALSE)

```

```
#modelo auto.arima bota #1,0,0,1,1,2 12
```

```
#valor de lambda
```

```
BoxCox.lambda(EEUU_Mexico)
```

```
#T Test--
```

```
tabla<-
```

```
sarima(EEUU_Mexico%>%BoxCox(lambda=BoxCox.lambda(EEUU_Mexico)),p=2,d=1,q=2,  
P=2,D=1,Q=2,S=12)
```

```
tabla$table
```

```
#modelo final post verificación con la prueba t 3 1 3 2 1 2
```

```
#probar el modelo
```

```
Arima(window(EEUU_Mexico,end=2017),order=c(1,0,0),seasonal =  
list(order=c(1,1,1),period=12),lambda=BoxCox.lambda(EEUU_Mexico))%>%forecast(h=12)  
%>%autoplot() +autolayer(window(EEUU_Mexico,end=2019),series="Mexico_exp")
```

```
checkresiduals(Arima(window(EEUU_Mexico,end=2018),order=c(1,1,1),seasonal =  
list(order=c(2,1,0),period=12),lambda=0.2874526))
```

```
#proyeccion
```

```
Arima(EEUU_Mexico,order=c(3,1,3),seasonal=list(order=c(2,1,2),period=12),lambda=BoxCo  
x.lambda(EEUU_Mexico))%>%forecast(h=12)%>%autoplot()
```

```
EEUU_Mexico_proy<-
```

```
Arima(EEUU_Mexico,order=c(3,1,3),seasonal=list(order=c(2,1,2),period=12),lambda=BoxCo  
x.lambda(EEUU_Mexico))%>%forecast(h=17)
```

```
#Augmented Dickey-Fuller test es para ver si es estacionaria, si es menor a 0.05 lo es, si no  
lo es se necesita
```

```
# diferenciar una vez más y así.
```

```
adf.test(diff(diff(EEUU_Mexico%>%BoxCox(lambda=BoxCox.lambda(EEUU_Mexico))),lag=1
2),alternative="stationary",k=12)
```

```
#Es estacionario
```

```
# p-value 0.01
```

```
#####
#####          Chile          #####
#####
```

```
#Comportamiento del exportador Chileno
```

```
autoplot(EEUU_Chile)
```

```
#Post-Tratamiento a la serie de tiempo
```

```
autoplot(EEUU_Chile%>%BoxCox(lambda=BoxCox.lambda(EEUU_Chile)))
```

```
autoplot(diff(EEUU_Chile%>%BoxCox(lambda=BoxCox.lambda(EEUU_Chile))))
```

```
#Comportamiento mensual contrastando por años
```

```
ggplotly(ggseasonplot(EEUU_Chile)) ## tiene un crecimiento pero baja por los meses de
mayo a agosto y sube
```

```
## en de Octubre a Marzo exportan más
```

```
# Ljung Box test es para saber si es un ruido blanco p-value < 2.2e-16
```

```
Box.test(EEUU_Chile,lag=12,type="Ljung")
```

```
# p-value < 2.2e-16 , no es un ruido blanco bien
```

```
# se necesita 1 y 1 estacional
```

```
EEUU_Chile%>%diff()%>%nsdiffs()
```

```
# ¿Su estacionalidad?
```

```
BoxCox.lambda(EEUU_Chile)
```

```
acf2(diff(diff(EEUU_Chile))%>%BoxCox(lambda=BoxCox.lambda(EEUU_Chile)),lag=12))
```

```
## su estacionalidad es de 12
```

```
#Modelo
```

```
fit2<-auto.arima(EEUU_Chile,lambda = BoxCox.lambda(EEUU_Chile),stepwise =  
FALSE,max.order=50,approximation = FALSE)
```

```
#modelo bota #1 0 0 2 1 0 12
```

```
#T Test modelo fit
```

```
tabla<-
```

```
sarima(EEUU_Chile%>%BoxCox(BoxCox.lambda(EEUU_Chile)),p=1,d=1,q=1,P=2,D=1,Q=0  
,S=12)
```

```
tabla$table
```

```
checkresiduals(fit)
```

```
checkresiduals(Arima(window(EEUU_Chile,end=2018),order=c(2,1,1),seasonal =  
list(order=c(1,0,1),period=12),lambda=0.2874526))
```

```
#modelo final post verificación con el t-test ##1 0 0 0 1 1
```

```
#probar el modelo
```

```
Arima(window(EEUU_Chile,end=2018),order=c(1,1,1),seasonal =  
list(order=c(2,1,0),period=12),lambda=BoxCox.lambda(EEUU_Chile))%>%forecast(h=12)%>  
%autoplot()+autolayer(window(EEUU_Chile,end=2020),series="Chile_exp")
```

```
checkresiduals(Arima(window(EEUU_Chile,end=2018),order=c(1,1,1),seasonal =  
list(order=c(2,1,0),period=12),lambda=BoxCox.lambda(EEUU_Chile)))
```

```
#proyeccion
```

```
Arima(EEUU_Chile,order=c(1,0,0),seasonal=list(order=c(0,1,1),period=12),lambda=BoxCox.l  
ambda(EEUU_Chile))%>%forecast(h=12)%>%autoplot()
```

```

EEUU_Chile_proy<-
Arima(EEUU_Chile,order=c(1,0,0),seasonal=list(order=c(0,1,1),period=12),lambda=BoxCox.l
ambda(EEUU_Chile))%>%forecast(h=17)

#Augmented Dickey-Fuller test es para ver si es estacionaria, si es menor a 0.05 lo es, si no
lo es se necesita

# diferenciar una vez más y así. Es estacionario con D 1 y lambda

adf.test(diff((EEUU_Chile%>%BoxCox(lambda=BoxCox.lambda(EEUU_Chile))),lag=12),alter
native="stationary",k=12)

#####
#####                      Rep Dominicana                      #####
#####

#Comportamiento de Rep.Dominicana
autoplot(EEUU_Rep)
autoplot(EEUU_Rep%>%BoxCox(lambda= BoxCox.lambda(EEUU_Rep)))

#Post- tratamiento a la serie de tiempo
autoplot(diff(diff(EEUU_Rep)%>%BoxCox(lambda= BoxCox.lambda(EEUU_Rep))),lag=12))

#Grafico mensual por años
ggplotly(ggseasonplot(EEUU_Rep)) ## tiene un crecimiento pero baja por los meses de
mayo a agosto y sube

## en de Octubre a Marzo

# Ljung Box test es para saber si es un ruido blanco  p-value < 2.2e-16
Box.test(EEUU_Rep,lag=12,type="Ljung")

```

```

# p-value < 2.2e-16 , no es un ruido blanco bien
# se necesitan 1 y 1 estacional
EEUU_Rep%>%nsdiffs()
# ¿Su estacionalidad?
BoxCox.lambda(EEUU_Rep)
acf2(diff(diff(EEUU_Rep)%>%BoxCox(lambda= BoxCox.lambda(EEUU_Rep)),lag=12))
## su estacionalidad es de 12
#Modelo

fit3<-auto.arima(EEUU_Rep,lambda = BoxCox.lambda(EEUU_Rep),stepwise =
FALSE,max.order=50,approximation = FALSE)
#modelo bota #1 0 0 0 1 1 12

#T Test modelo fit
tabla<-
sarima(EEUU_Rep%>%BoxCox(BoxCox.lambda(EEUU_Rep)),p=1,d=1,q=1,P=0,D=1,Q=1,S
=12)
tabla$table

#T Test
tabla<-
sarima(EEUU_Rep%>%BoxCox(BoxCox.lambda(EEUU_Rep)),p=1,d=0,q=0,P=0,D=1,Q=1,S
=12)
tabla$table

checkresiduals(fit3)

checkresiduals(Arima(window(EEUU_Rep,end=2018),order=c(1,0,1),seasonal =
list(order=c(1,0,1),period=12),lambda=0.2874526))

```

#modelo final post verificación con el t.test #1 1 1 0 1 1 12

#probar el modelo

```
Arima(window(EUU_Rep,end=2018),order=c(1,0,0),seasonal =  
list(order=c(0,1,1),period=12),lambda=BoxCox.lambda(EUU_Rep))%>%forecast(h=12)%>  
%autoplot()+autolayer(window(EUU_Rep,end=2020),series="Republica dominica_exp")
```

```
checkresiduals(Arima(EUU_Rep,order=c(0,1,0),seasonal =  
list(order=c(0,1,1),period=12),lambda=BoxCox.lambda(EUU_Rep)))
```

#proyeccion

```
Arima(EUU_Rep,order=c(1,1,1),seasonal=list(order=c(0,1,1),period=12),lambda=BoxCox.la  
mbda(EUU_Rep))%>%forecast(h=12)%>%autoplot()
```

```
EEUU_Rep_proy<-  
Arima(EUU_Rep,order=c(1,1,1),seasonal=list(order=c(0,1,1),period=12),lambda=BoxCox.la  
mbda(EUU_Rep))%>%forecast(h=17)
```

#Augmented Dickey-Fuller test es para ver si es estacionaria, si es menor a 0.05 lo es, si no lo es se necesita

# diferenciar una vez más y así. Es estacionario con D 1 y lambda

```
adf.test(diff(EUU_Rep%>%BoxCox(lambda=BoxCox.lambda(EUU_Rep)),lag=12),alternati  
ve="stationary",k=12)
```

```
#####  
##### Perú #####  
#####
```

#Ya no se realizará ARIMA debido a que al probarlo no sale un resultado adecuado, por eso

#se procederá a realizar con métodos no paramétricos



###HW

```
window(EEUU_Peru,start=2014)%>%ets()%>%forecast(h=12)%>%autoplot(PI = TRUE)
```

```
fit355<-auto.arima(EEUU_Peru,lambda = BoxCox.lambda(EEUU_Peru),stepwise =  
FALSE,max.order=50,approximation = FALSE)
```

```
tabla<-
```

```
sarima(EEUU_Peru%>%BoxCox(BoxCox.lambda(EEUU_Peru)),p=1,d=0,q=0,P=0,D=1,Q=1,  
S=12)
```

```
tabla$table
```

```
Arima(EEUU_Peru,order=c(1,0,1),seasonal=list(order=c(0,1,1),period=12),lambda=BoxCox.l  
ambda(EEUU_Peru))%>%forecast(h=12)%>%autoplot()
```

#1 0 0 0 1 1 sale el modelo pero como se ve no se cumplen los supuestos y el resultado sale fallido

```
EEUU_Peru1<-EEUU_Peru
```

```
EEUU_Peru1[EEUU_Peru1==0]<-1
```

#Se utilizará HoltWinters,método no paramétrico

```
HoltWinters(window(EEUU_Peru1,start=2011),seasonal="multiplicative")%>%forecast(h=17)  
%>%autoplot()
```

```
EEUU_Peru_proy<-
```

```
HoltWinters(window(EEUU_Peru1,start=2011),seasonal="multiplicative")%>%forecast(h=17)
```

```
#####  
#####  
##### Paises Bajos #####  
#####  
#####
```

```
Paises_bajos_imp<-Paises_bajos_imp%>%arrange(Año.Mes)
```

```
Paises_bajos_imp<-Paises_bajos_imp[,c(6,7,8,9,10)] # colombia no porque está bajando
```

```
dates <- seq(as.Date("2007-11-01"), length = 153, by = "months")
```

```

Paises_bajos_imp<-cbind(Paises_bajos_imp,dates)
Paises_bajos_imp<-Paises_bajos_imp[,c(6,5,1,2,3,4)]
Paises_bajos<-ts(Paises_bajos_imp[,c(2,3,4,5,6)],start=c(2007,11),frequency = 12)
autoplot(window(Paises_bajos,start=2014))+ theme_classic()+
  theme(axis.text = element_text(size = 12),axis.title =
element_text(size=14),legend.title=element_text(size=14),legend.text=element_text(size=12)
,title=element_text(size=18))+ ylab("Toneladas de palta")+xlab("Meses")+labs(title =
"Importaciones de Países Bajos" ,color='Países')

```

#Gráfico mensual que se contrasta según los años

```

ggplotly(ggseasonplot(window(Paises_bajos[,1],start=2014)))
ggseasonplot(window(Paises_bajos[,3],start=2014))+ theme_classic()+
  theme(axis.text = element_text(size = 12),axis.title =
element_text(size=14),legend.title=element_text(size=14),legend.text=element_text(size=12)
,title=element_text(size=18))+ ylab("Toneladas de palta")+xlab("Meses")+labs(title =
"Importaciones mensuales de Países Bajos" ,color='Años')

```

#Peru tiene subida de producción cuando México cae, potencial mercado

# Se divide por exportado a Países Bajos

```

Paises_bajos_Chile<-Paises_bajos[,1]
Paises_bajos_Sudafrica<-Paises_bajos[,2]
Paises_bajos_Peru<-Paises_bajos[,3]
Paises_bajos_Kenya<-Paises_bajos[,4]
Paises_bajos_Mexico<-Paises_bajos[,5]

```

```
#####  
##### Chile #####  
#####
```

#El proceso será el mismo, se utilizará los métodos no paramétricos ya que al probar con ARIMA

#al igual con Perú en EEUU, no se cumplen los test.

```
Paises_bajos_Chile1<-Paises_bajos_Chile  
Paises_bajos_Chile1[Paises_bajos_Chile1==0]<-1  
HoltWinters(window(Paises_bajos_Chile1,start=2014),seasonal="multiplicative")%>%forecast  
(h=12)%>%autoplot()
```

```
Paises_bajos_Chile_proy<-  
HoltWinters(window(Paises_bajos_Chile1,start=2014),seasonal="multiplicative")%>%forecast  
(h=17)
```

```
#####  
##### Sudafrica #####  
#####
```

#El proceso será el mismo, se utilizará los métodos no paramétricos ya que al probar con ARIMA

#al igual con Perú en EEUU, no se cumplen los test.

```
Paises_bajos_Sudafrica1<-Paises_bajos_Sudafrica  
Paises_bajos_Sudafrica1[Paises_bajos_Sudafrica1==0]<-1  
HoltWinters(window(Paises_bajos_Sudafrica1,start=2014),seasonal="additive")%>%forecast  
(h=12)%>%autoplot()
```

```
Paises_bajos_Sudafrica_proy<-
HoltWinters(window(Paises_bajos_Sudafrica1,start=2014),seasonal="additive")%>%forecast
(h=17)
```

```
#####
#####                Peru                #####
#####
```

```
#La función ets y la HoltWinters utilizan el mismo método pero con diferente enfoque
#Debido a eso se prueba con las dos y con ayuda del contexto se opta por una, esta vez por
la ets
```

```
Paises_bajos_Peru1<-Paises_bajos_Peru
Paises_bajos_Peru1[Paises_bajos_Peru1==0]<-1
HoltWinters(window(Paises_bajos_Peru1,start=2014),seasonal="multiplicative")%>%forecas
t(h=17)%>%autoplot()
```

```
plot(stlf(window(Paises_bajos_Peru1,start=2014)))
ets(window(Paises_bajos_Peru1,start=2014))%>%forecast(h=17)%>%autoplot()
Paises_bajos_Peru_proy<-ets(window(Paises_bajos_Peru1,start=2014))%>%forecast(h=17)
```

```
#####
#####                Kenya                #####
#####
```

```
#Se opta por el método HoltWinters
```

```
Paises_bajos_Kenya1<-Paises_bajos_Kenya
Paises_bajos_Kenya1[Paises_bajos_Kenya1==0]<-1
```

```
HoltWinters(window(Paises_bajos_Kenya1,start=2015),seasonal="additive")%>%forecast(h=12)%>%autoplot()
```

```
Paises_bajos_Kenya_proy<-
```

```
HoltWinters(window(Paises_bajos_Kenya1,start=2014),seasonal="additive")%>%forecast(h=17)
```

```
#####  
##### Mexico #####  
#####
```

```
#Se opta por el método HoltWinters
```

```
Paises_bajos_Mexico1<-Paises_bajos_Mexico
```

```
Paises_bajos_Mexico1[Paises_bajos_Mexico1==0]<-1
```

```
HoltWinters(window(Paises_bajos_Mexico1,start=2014),seasonal="multiplicative")%>%forecast(h=12)%>%autoplot()
```

```
Paises_bajos_Mexico_proy<-
```

```
HoltWinters(window(Paises_bajos_Mexico1,start=2014),seasonal="multiplicative")%>%forecast(h=17)
```

```
##### Proyecciones #####
```

```
### EEUU
```

```
EEUU_Mexico_proy%>%autoplot()
```

```
str(EEUU_Mexico_proy)
```

```
as.ts(EEUU_Mexico_proy)%>%autoplot()
```

```
EEUU_Mexico_proy$x
```

```
EEUU_Mexico_proy$mean
```

```
valores<-rbind(as.matrix(EEUU_Mexico_proy$x),as.matrix(EEUU_Mexico_proy$mean))
```

```

count(as.data.frame(EEUU_Mexico_proy$x))+12

fechas<-seq(as.Date("2007-12-01"), length = 164, by = "months")

DF<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

colnames(DF)<-c("Fechas","EEUU_Mexico_proy")

```

#Coger data de cada uno, luego convertir a ts las proyecciones y un rbind

```

EEUU_Chile_proy%>%autoplot()

EEUU_Chile_proy$x

EEUU_Chile_proy$mean

valores<-rbind(as.matrix(EEUU_Chile_proy$x),as.matrix(EEUU_Chile_proy$mean))

count(as.data.frame(EEUU_Chile_proy$x))+12

fechas<-seq(as.Date("2007-12-01"), length = 164, by = "months")

df1<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF2<-cbind(DF,df1[,2])

colnames(DF2)<-c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy")

EEUU_Rep_proy%>%autoplot()

EEUU_Rep_proy$x

EEUU_Rep_proy$mean

valores<-rbind(as.matrix(EEUU_Rep_proy$x),as.matrix(EEUU_Rep_proy$mean))

count(as.data.frame(EEUU_Rep_proy$x))+12

fechas<-seq(as.Date("2007-12-01"), length = 164, by = "months")

df2<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF3<-cbind(DF2,df2[,2])

```

```

colnames(DF3)<-c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy")
EEUU_Peru_proy%>%autoplot()

valores3<-rbind(as.matrix(EEUU_Peru_proy$x),as.matrix(EEUU_Peru_proy$mean))

count(as.data.frame(EEUU_Peru_proy$x))+12

fechas<-seq(as.Date("2011-01-01"), length = 127, by = "months")

df3<-cbind(fechas,as.data.frame(valores3))%>%filter(fechas>=as.Date("2014-01-01"))

DF4<-cbind(DF3,df3[,2])

colnames(DF4)<-
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy
")

### Paises bajos ###

Paises_bajos_Chile_proy%>%autoplot()

valores<-
rbind(as.matrix(Paises_bajos_Chile_proy$x),as.matrix(Paises_bajos_Chile_proy$mean))

count(as.data.frame(Paises_bajos_Chile_proy$x))+12

fechas<-seq(as.Date("2014-01-01"), length = 91, by = "months")

df4<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF5<-cbind(DF4,df4[,2])

colnames(DF5)<-
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy
","Paises_bajos_Chile_proy")

Paises_bajos_Sudafrica_proy%>%autoplot()

valores<-
rbind(as.matrix(Paises_bajos_Sudafrica_proy$x),as.matrix(Paises_bajos_Sudafrica_proy$m
ean))

```

```

count(as.data.frame(Paises_bajos_Sudafrica_proy$x))+12

fechas<-seq(as.Date("2014-01-01"), length = 91, by = "months")

df5<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF6<-cbind(DF5,df5[,2])

colnames(DF6)<-
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy",
,"Paises_bajos_Chile_proy","Paises_bajos_Sudafrica_proy")

```

```

Paises_bajos_Peru_proy%>%autoplot()

valores<-
rbind(as.matrix(Paises_bajos_Peru_proy$x),as.matrix(Paises_bajos_Peru_proy$mean))

count(as.data.frame(Paises_bajos_Peru_proy$x))+12

fechas<-seq(as.Date("2014-01-01"), length = 91, by = "months")

df6<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF7<-cbind(DF6,df6[,2])

colnames(DF7)<-
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy",
,"Paises_bajos_Chile_proy","Paises_bajos_Sudafrica_proy","Paises_bajos_Peru_proy")

```

```

Paises_bajos_Kenya_proy%>%autoplot()

valores<-
rbind(as.matrix(Paises_bajos_Kenya_proy$x),as.matrix(Paises_bajos_Kenya_proy$mean))

count(as.data.frame(Paises_bajos_Kenya_proy$x))+12

fechas<-seq(as.Date("2014-01-01"), length = 91, by = "months")

df7<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF8<-cbind(DF7,df7[,2])

```



```
colnames(DF8)<-
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy
","Paises_bajos_Chile_proy","Paises_bajos_Sudafrica_proy","Paises_bajos_Peru_proy","Pai
ses_bajos_Kenya_proy")
```

```
Paises_bajos_Mexico_proy%>%autoplot()
```

```
valores<-
```

```
rbind(as.matrix(Paises_bajos_Mexico_proy$x),as.matrix(Paises_bajos_Mexico_proy$mean))
```

```
count(as.data.frame(Paises_bajos_Mexico_proy$x))+12
```

```
fechas<-seq(as.Date("2014-01-01"), length = 91, by = "months")
```

```
df8<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))
```

```
DF9<-cbind(DF8,df8[,2])
```

```
colnames(DF9)<-
```

```
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy
","Paises_bajos_Chile_proy","Paises_bajos_Sudafrica_proy","Paises_bajos_Peru_proy","Pai
ses_bajos_Kenya_proy","Paises_bajos_Mexico_proy")
```

```
### China no tiene el 2020
```

```
China_Mexico_proy%>%autoplot()
```

```
valores<-rbind(as.matrix(China_Mexico_proy$x),as.matrix(China_Mexico_proy$mean))
```

```
count(as.data.frame(China_Mexico_proy$x))+12
```

```
fechas<-seq(as.Date("2014-01-01"), length = 84, by = "months")
```

```
df9<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))
```

```
DF10<-cbind(DF9,df9[,2])
```

```
colnames(DF10)<-
```

```
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy
","Paises_bajos_Chile_proy","Paises_bajos_Sudafrica_proy","Paises_bajos_Peru_proy","Pai
ses_bajos_Kenya_proy","Paises_bajos_Mexico_proy","China_Mexico_proy")
```

```

China_Chile_proy%>%autoplot()

valores<-rbind(as.matrix(China_Chile_proy$x),as.matrix(China_Chile_proy$mean))

count(as.data.frame(China_Chile_proy$x))+12

fechas<-seq(as.Date("2014-01-01"), length = 84, by = "months")

df10<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF11<-cbind(DF10,df10[,2])

colnames(DF11)<-
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy",
,"Paises_bajos_Chile_proy","Paises_bajos_Sudafrica_proy","Paises_bajos_Peru_proy","Pai
ses_bajos_Kenya_proy","Paises_bajos_Mexico_proy","China_Mexico_proy","China_Chile_p
roy")

```

```

China_Peru_proy%>%autoplot()

valores<-rbind(as.matrix(China_Peru_proy$x),as.matrix(China_Peru_proy$mean))

count(as.data.frame(China_Peru_proy$x))+12

fechas<-seq(as.Date("2014-01-01"), length = 84, by = "months")

df11<-cbind(fechas,as.data.frame(valores))%>%filter(fechas>=as.Date("2014-01-01"))

DF12<-cbind(DF11,df11[,2])

colnames(DF12)<-
c("Fechas","EEUU_Mexico_proy","EEUU_Chile_proy","EEUU_Rep_proy","EEUU_Peru_proy",
,"Paises_bajos_Chile_proy","Paises_bajos_Sudafrica_proy","Paises_bajos_Peru_proy","Pai
ses_bajos_Kenya_proy","Paises_bajos_Mexico_proy","China_Mexico_proy","China_Chile_p
roy","China_Peru_proy")

```

#EEUU

EEUU\_Mexico

EEUU\_Mexico\_proy\$mean

```

cbind(EEUU_Mexico,EEUU_Mexico_proy$mean)

Mexico<-
window(ts(c(EEUU_Mexico,EEUU_Mexico_proy$mean),start=start(EEUU_Mexico),frequency
y = frequency(EEUU_Mexico)),start=2013)

EEUU_Chile

EEUU_Chile_proy$mean

Chile<-
window(ts(c(EEUU_Chile,EEUU_Chile_proy$mean),start=start(EEUU_Chile),frequency =
frequency(EEUU_Chile)),start=2013)

EEUU_Rep

EEUU_Rep_proy$mean

Republica_Dominicana<-
window(ts(c(EEUU_Rep,EEUU_Rep_proy$mean),start=start(EEUU_Rep),frequency =
frequency(EEUU_Rep)),start=2013)

EEUU_Peru%>%autoplot()

EEUU_Peru_proy$mean

Peru<-
window(ts(c(EEUU_Peru,EEUU_Peru_proy$mean),start=start(EEUU_Peru),frequency =
frequency(EEUU_Peru)),start=2013)

Peru%>%autoplot()

Mundo<-Mexico+Chile+Republica_Dominicana+Peru

ts.union(Mexico,Chile,Republica_Dominicana,Peru,Mundo)%>%autoplot()+theme_classic()+
  theme(axis.text = element_text(size = 9),axis.title =
  element_text(size=11),legend.title=element_text(size=10),legend.text=element_text(size=9),t
  itle=element_text(size=15))+

```

```
ylab("Toneladas de palta")+xlab("Meses")+labs(title = "Importaciones de Estados Unidos  
con la proyección",color='Países')
```

```
#PB
```

```
Países_bajos_Chile
```

```
Países_bajos_Chile_proy$mean
```

```
Chile<-
```

```
window(ts(c(Países_bajos_Chile,Países_bajos_Chile_proy$mean),start=start(Países_bajos_  
Chile),frequency = frequency(Países_bajos_Chile)),start=2015)
```

```
Países_bajos_Sudafrica
```

```
Países_bajos_Sudafrica_proy$mean
```

```
Sudafrica<-
```

```
window(ts(c(Países_bajos_Sudafrica,Países_bajos_Sudafrica_proy$mean),start=start(Países_  
s_bajos_Sudafrica),frequency = frequency(Países_bajos_Sudafrica)),start=2015)
```

```
Países_bajos_Peru
```

```
Países_bajos_Peru_proy$mean
```

```
Peru<-
```

```
window(ts(c(Países_bajos_Peru,Países_bajos_Peru_proy$mean),start=start(Países_bajos_  
Peru),frequency = frequency(Países_bajos_Peru)),start=2015)
```

```
Países_bajos_Kenya
```

```
Países_bajos_Kenya_proy$mean
```

```
Kenya<-
```

```
window(ts(c(Países_bajos_Kenya,Países_bajos_Kenya_proy$mean),start=start(Países_bajo  
s_Kenya),frequency = frequency(Países_bajos_Kenya)),start=2015)
```

```
Países_bajos_Mexico
```

```
Paises_bajos_Mexico_proy$mean
```

```
Mexico<-
```

```
window(ts(c(Paises_bajos_Mexico,Paises_bajos_Mexico_proy$mean),start=start(Paises_bajos_Mexico),frequency = frequency(Paises_bajos_Mexico)),start=2015)
```

```
Mundo<-Chile+Sudafrica+Peru+Kenya+Mexico
```

```
ts.union(Chile,Sudafrica,Peru,Kenya,Mexico,Mundo)%>%autoplot()+theme_classic()+
```

```
  theme(axis.text = element_text(size = 9),axis.title =  
  element_text(size=11),legend.title=element_text(size=10),legend.text=element_text(size=9),title=element_text(size=15))+
```

```
  ylab("Toneladas de palta")+xlab("Meses")+labs(title = "Importaciones de Países Bajos con la proyección",color='Países')
```

```
#Datos finales
```

```
#2020
```

```
EEUU_Peru_2020<-  
round(rbind(as.matrix(window(EEUU_Peru,start=2020)),as.matrix(EEUU_Peru_proy$mean))  
[1:12],0)
```

```
PB_Peru_2020<-  
round(rbind(as.matrix(window(Paises_bajos_Peru,start=2020)),as.matrix(Paises_bajos_Peru_proy$mean))[1:12],0)
```

```
#2021
```

```
EEUU_Peru_proy_2021<-round(as.matrix(EEUU_Peru_proy$mean)[6:17,],0)
```

```
PB_Peru_proy_2021<-round(as.matrix(Paises_bajos_Peru_proy$mean)[6:17,],0)
```

```
#Total a Países Bajos
```

```
PB_Peru_2020
```

PB\_Peru\_proy\_2021

#Total a EEUU

EEUU\_Peru\_2020

EEUU\_Peru\_proy\_2021

