

**XVII CONGRESO INTERNACIONAL DE COSTOS del IIC
SEVILLA 2021**

**MODELOS DE CONTABILIDAD DIRECTIVA PARA OPTIMIZAR EL
UNBUNDLING APALANCADO POR MINERÍA DE DATOS**

Categoría propuesta: Aportes a la disciplina

Autores

**Daniel Farré (UBA-Socio IAPUCo)
Paula Lucía Farré (IBYME-CONICET)**

Numero telefónico: 541149471933

Sevilla, Octubre 2021

Modelos de Contabilidad Directiva para optimizar el *unbundling*
apalancado por minería de datos
Categoría propuesta: Aportes a la disciplina

Resumen

El avance exponencial de la Ciencia de Datos durante la última década permite optimizar todo tipo de técnicas tradicionales de gestión. En la presente ponencia ponemos foco en la aplicación de enfoques y modelos de Gestión y Costos sobre la técnica de Desagregación (*Unbundling*) de Mercadotecnia, potenciado por el análisis de grupos con aprendizaje automatizado (*Clustering* con *machine learning*) de la Minería de Datos.

La combinación de modelos de Gestión sobre el *unbundling* tradicional en empresas de mercados competitivos (de elasticidad conocida) que estuviesen operando en óptimos de mercado con desaprovechamiento de capacidad permite optimizar el nuevo precio para lograr objetivos múltiples: aumento de participación de mercado y rentabilidad y disminución de capacidad ociosa.

Yendo más lejos aún, la incorporación de la técnica de *clustering* con aprendizaje automatizado a dichos modelos permite un análisis de mayor granularidad del comportamiento del mercado ante el *unbundling*, aumentando los beneficios por la segmentación de ofertas.

INDICE

- 1) Introducción
- 2) Razón de ser
- 3) Marco Teórico:
 - a. Modelo de optimización de precios en función de elasticidad conocida
 - b. *Unbundling* como técnica de mercadotecnia
 - c. Análisis de grupos con aprendizaje automatizado (*Clustering* con *Machine Learning*)
- 4) Casuística base
- 5) Reducción de precio para aumentar la participación de mercado
- 6) Casuística de mayor complejidad: comportamientos diferentes en distintos segmentos
- 7) Modelización simplificada
- 8) Conclusiones
- 9) Bibliografía

1) INTRODUCCIÓN

Uno de los principios que más aportó al éxito del concepto original de Cadena de Valor (Porter, 1985) en la Contabilidad Directiva fue la comparación entre el valor agregado al cliente y el costo necesario para lograr su satisfacción, discriminando eslabón por eslabón en la visión Meso-económica y actividad por actividad dentro de cada eslabón, en la visión Micro-económica. Si se detecta que una actividad aporta menor valor que su costo, esta no tiene sentido económico, por cuanto se dispara un proceso de revisión para eliminarla (u optimizarla para mejorar su aporte o disminuir su costo).

Desde el punto de vista de Mercadotecnia, si dicha actividad o conjunto de actividades se realizan para lograr un componente del producto que es factible desasociar al producto principal, en muchas ocasiones se procede a realizar su desagregación o *unbundling*, lo que permite un ahorro de costos que debiera ser mayor a la pérdida de ingresos por la reducción de precio (disminución del valor percibido de dicho componente) sin pérdida de volumen de ventas.

Ahora bien, no todos los clientes perciben el valor de la misma manera. Decidir en función de grandes promedios da lugar a resultados con desvíos que pueden ser relevantes. El avance exponencial de la Ciencia de Datos durante la última década permite mejorar el entendimiento de esas percepciones segmentadas por grupos y nos da la posibilidad de elaborar modelos de Toma de Decisiones más precisos.

Adicionalmente, al cambiar las variables precio, costos variables y margen de contribución, podemos aplicar modelos de Contabilidad de Gestión con foco en la elasticidad precio-demanda para demostrar que los beneficios no sólo serán los detectados en la cadena de valor.

2) RAZÓN DE SER

La ponencia tiene por objetivo analizar distintos casos de *unbundling* en empresas de mercados competitivos (de elasticidad conocida) que estuviesen operando en óptimos de mercado con desaprovechamiento de capacidad, partiendo de un escenario base sin percepción de impacto en el valor de los componentes de producto desagregados y evolucionando a casuísticas en donde existen distintas brechas negativas entre el valor aportado y los costos de las actividades a eliminar, de acuerdo a diferentes *clusters* de clientes, identificados en ejercicios de aplicación de modelos de minería de datos.

Para cada caso se determinan nuevos óptimos de precios y participación de mercados segmentados, más allá de las reducciones tradicionales por el efecto del desagregado de productos.

La modelización se simplifica asumiendo las siguientes características:

- Modelo determinista (Si se desea transformar en un modelo estocástico se podrán utilizar los mismos lineamientos, pero utilizando matemática borrosa)
- Maximización de valor agregado (neteando, de los ingresos, todos los costos con visión económica de la Teoría General de Costos) como objetivo económico.
- Elasticidad precio-demanda conocida (constante sólo dentro de todo el nivel de actividad en análisis) en base a estudios de mercado (que determina una curva cuadrática en base a la cercanía de estas con los distintos puntos observados, lo que equivale a decir que existe un comportamiento lineal de la función de cantidad en función de precio dentro de dicho rango):
 - General en el caso base

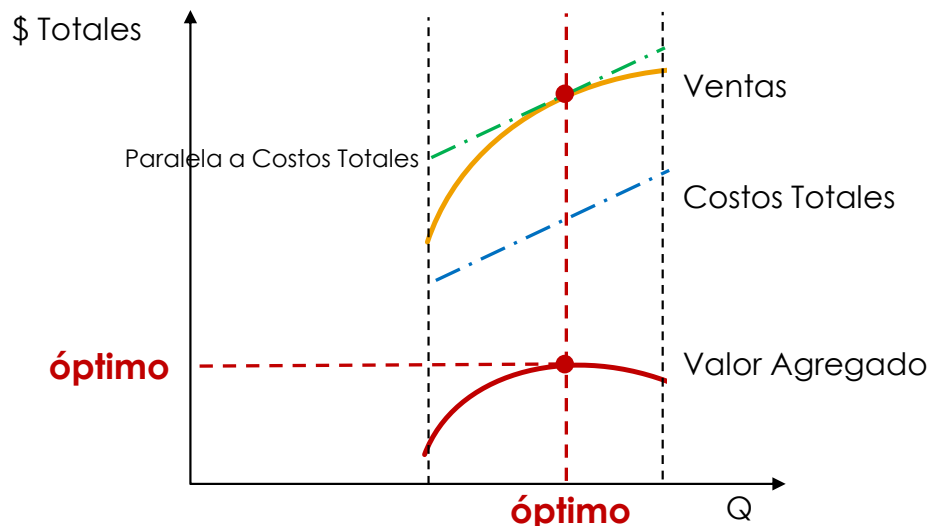
- Segmentado bajo criterios de comportamientos asociados al valor percibido para los casos siguientes.
- En dicho nivel de actividad se mantienen constantes los Costos Fijos Totales (Estructurales y Operativos) y el costo variable unitario.

3) MARCO TEÓRICO

La ponencia toma como base los siguientes desarrollos teóricos:

- Modelo de optimización de precios en función de elasticidad conocida (Autores omitidos)

De acuerdo con lo desarrollado en (autores omitidos), y bajo los supuestos citados, en la situación base óptima previo a la detección de la falta de agregado de valor, el comportamiento de los costos totales es lineal dentro del rango, y el comportamiento de las ventas y el valor agregado se representan por curvas cuadráticas negativas (influenciadas por la elasticidad precio-demanda), como se visualiza en la Gráfica #1.



Gráfica #1 – Elaboración propia

La situación óptima se logra cuando la paralela de los Costos Totales es tangente a la curva de ingresos, o bien cuando la curva cuadrática que surge de la resta de ventas menos los costos totales llega a su valor máximo (tangente nula de dicha curva), como se muestra en la Gráfica #1.

Si la Elasticidad precio-demanda se mide en dicho punto óptimo (tomado como escenario base, momento 0), observaremos que el margen de contribución (mc^0) será igual a la inversa de la Elasticidad precio-demanda (ϵ^0) con signo contrario, fundamentados en el resultado nulo de la optimización de precios en mercados competitivos de la Expresión I (autores omitidos):

Expresión I

$$\frac{\delta p}{p^0} = - \frac{\epsilon^0 - 1 + mc^0}{2}$$

b. *Unbundling* como técnica de mercadotecnia

La agregación (*bundling*) es un proceso de mercadotecnia que consiste en combinar varios productos o servicios dentro de una oferta única a menor valor que si se compraran por separado. Se lo realiza con objetivos de aumento de participación en el mercado, maximización de ingresos y/o diferenciación de producto *versus* la competencia. Podemos citar como ejemplo la incorporación de seguros de viajero capitados al producto Tarjeta de Crédito para segmentos *premium*.

La desagregación (*unbundling*) es el proceso contrario, cuando notamos que, en algún ofrecimiento que fue diseñado con un cúmulo de agregados, alguno de estos no es percibido como un diferencial que aporta valor y se lo desprende del combinado reduciendo el precio total para lograr mejorar la relación precio/valor percibido.

c. Análisis de grupos con aprendizaje automatizado (*Clustering con Machine Learning*)

Cada día que pasa, la minería de datos aporta algoritmos de aprendizaje automático de mayor precisión y menor costo. A diferencia de la clasificación, que es un método de aprendizaje supervisado por el analista, el *clustering* es un método de aprendizaje automatizado no supervisado. El código (habitualmente escrito en lenguajes como R o Python) utilizado en la minería de datos analiza un gran volumen de información dando como resultado agrupamientos en función de patrones “ocultos” en los datos, sin partir de hipótesis de relaciones aportadas por el especialista.

Existen distintos tipos de algoritmos de agrupación en segmentos (R.Sharma, 2020):

- *K-Means*: Partiendo de un número predefinido (k segmentos), calcula la distancia de cada punto de datos desde el centroide de cada segmento, y lo asigna en función de su distancia. Crean *clusters* de forma esferoide. Son apropiados cuando los segmentos se encuentran claramente separados.
- Agrupamiento jerárquico aglomerativo (enfoque ascendente): Parte considerando cada punto de datos como un clúster y luego los va fusionando en función de similitudes de distancia.
- Agrupamiento jerárquico por división (enfoque descendente): Inversamente al anterior, parte con un único *cluster* y los va dividiendo en función de criterios de distancia. Definiendo la distancia a la cual uno quiera detenerse, es la cantidad de *clusters* que se tendrán en consecuencia.
- DBSCAN (*Density-based Spatial Clustering of Applications with Noise*): Es un método de agrupamiento basado en la densidad. Agrupa los puntos de datos que tienen muchos puntos de datos vecinos dentro de un radio determinado. Se utiliza cuando los datos se distribuyen en forma arbitraria.
- BIRCH (*Balanced Iterative Reducing and Clustering using Hierarchies*): Crea agrupamientos con síntesis de datos. Es apropiado en el caso de enormes conjuntos de datos, ya que primero resume los datos y luego usa esa síntesis para crear segmentos mediante procesos iterativos.

Previamente al *clustering*, se debe conocer qué herramientas de *Data Analytics* (DA) utilizar. La comunidad de científicos de datos suele compartir bibliotecas (*libraries*) de código de DA que se utilizan concomitantemente para elegir la mejor opción de cantidad de segmentos, en función del método elegido (por ejemplo, para predeterminarlo en el método *K-means*). Otros métodos utilizados son los denominados OPTICS (*Ordering Points to Identify Clustering Structure*), que crean gráficas de densidad para mejorar la interpretación visual de la estructura de los segmentos.

Una vez determinados los grupos y sus características esenciales, se emplearán herramientas de *Machine Learning* (ML) para predecir comportamientos futuros. Luego, cuando se analiza un nuevo elemento, se lo identifica por su similitud con uno de los grupos, infiriendo que tendrá un comportamiento similar.

4) CASUÍSTICA BASE

Partimos desde el escenario más simple: La empresa está operando en óptimos de mercado con desaprovechamiento de capacidad productiva y comercial (Gráfica #1 *ut supra*) pero identifica que ninguno de sus clientes da valor a un servicio complementario al producto principal (incluido en el combo que conforma el ofrecimiento agregado).

Resultado del producto X			
Precio de Venta:			80 \$/Kg
Costo Variable:			60 \$/Kg
Volumen:			100 Kg
Ventas:	100Kg x 80 \$/Kg	=	8.000 \$
Costos Variables:	100Kg x 60 \$/Kg	=	<u>(6.000 \$)</u>
Contribución Marginal:			2.000 \$
Costos Fijos			<u>(1.000 \$)</u>
Valor Agregado			1.000 \$

Ante dicha observación, se plantea la discontinuidad de dicho complemento (*unbundling* tradicional), sin reducción alguna del precio, entendiendo (supuesto asumido en esta casuística) que no generará pérdida de clientes, y podrá disminuir costos variables de 5 \$/kg y Costos Fijos recurrentes de 50\$ (Costos diferenciales, no hundidos). Esta acción proyecta agregar \$550 al resultado:

Nuevo resultado del producto X			
Precio de Venta:			80 \$/Kg
Costo Variable:	60 \$/Kg – 5 \$/Kg	=	55 \$/Kg
Volumen:			100 Kg
Ventas:	100Kg x 80 \$/Kg	=	8.000 \$
Costos Variables:	100Kg x 55 \$/Kg	=	<u>(5.500 \$)</u>
Contribución Marginal:			2.500 \$
Costos Fijos			<u>(950 \$)</u>
Valor Agregado			1.550 \$

5) REDUCCIÓN DE PRECIO PARA AUMENTAR LA PARTICIPACIÓN DE MERCADO

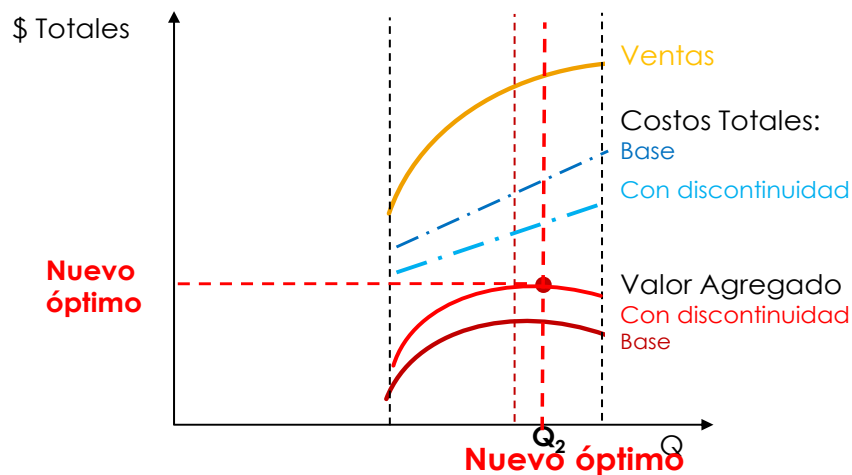
Dado el conocimiento del comportamiento del mercado competitivo y sabiendo la existencia de capacidad ociosa que se puede utilizar para el crecimiento, el departamento de Mercadotecnia propone trasladar el ahorro de costos variables al precio para aumentar el volumen de ventas. Sabiendo que la empresa estaba trabajando en su precio óptimo, con un margen de contribución del 25% (20\$/kg dividido 80\$/kg.), podemos deducir que la Elasticidad precio-demanda para dicho óptimo (100 kg.) es de -4, empleando el modelo teórico citado en el capítulo 3 (La inversa de 25% con signo contrario).

Una reducción de 6,25% del precio (5\$/kg relativizados al precio base de 80\$/kg) proyecta una propagación del volumen en un 25% (por su elasticidad de -4) asumiendo que la capacidad ociosa soporta dicho incremento, con lo cual el nuevo resultado no será mejor, como se demuestra en el cuadro siguiente:

Nuevo resultado del producto X			
Precio de Venta:	80 \$/Kg – 5 \$/Kg	=	75 \$/Kg
Costo Variable:			55 \$/Kg
Volumen:			125 Kg
Ventas:	125Kg x 75 \$/Kg	=	9.375 \$
Costos Variables:	125Kg x 55 \$/Kg	=	<u>(6.875 \$)</u>
Contribución Marginal:			2.500 \$
Costos Fijos			<u>(950 \$)</u>
Valor Agregado			1.550 \$

Si aplicamos el desarrollo presentado en el XLIII Congreso argentino de profesores universitarios de costos (Autores omitidos), la optimización del precio se logrará con el traslado de sólo la mitad del ahorro de los costos variables (2,5\$/kg, lo que representa un 3,125% de descuento). Propagando por la elasticidad de -4, resultará un aumento de volumen del 12,5% con los siguientes resultados, ahora sí óptimos, 31,25\$ mayor que las acciones habituales de los casos anteriores (Gráfica #2):

Nuevo resultado del producto X			
Precio de Venta:	80 \$/Kg – 2,50 \$/Kg	=	77,50 \$/Kg
Costo Variable:			55,00 \$/Kg
Volumen:			112,50 Kg
Ventas:	112,5Kg x 77,50 \$/Kg	=	8.718,75 \$
Costos Variables:	112,5Kg x 55 \$/Kg	=	<u>(6.187,50 \$)</u>
Contribución Marginal:			2.531,25 \$
Costos Fijos			<u>(950 \$)</u>
Valor Agregado			1.581,25 \$



Gráfica #2 – Elaboración propia

6) CASUÍSTICA DE MAYOR COMPLEJIDAD: COMPORTAMIENTOS DIFERENTES EN DISTINTOS SEGMENTOS

Hasta aquí, el caso base plantea que el 100% de los clientes actuales se comporta de la misma manera, y en ningún caso perciben valor por el servicio a discontinuar. ¿Qué pasa si existen segmentos de clientes que sí le dan valor mayor a la reducción de precio, mientras que otros son indiferentes? ¿Qué pasa si le dan valor, pero menor al costo agregado por el servicio complementario?

El modelo necesita optimizarse en dos aspectos:

- a) Analizar la opción de no discontinuar el servicio para toda la cartera, sino sólo para algunos *clusters*. Desde el punto de vista de los costos diferenciales a considerar en la modelización deberán incluirse los costos fijos recurrentes (no hundidos) en la comparación entre esta alternativa y la de eliminación total, pero no *versus* la situación de origen; en ésta, no se eliminan los costos fijos recurrentes, si bien son necesarios sólo para el segmento que valora el agregado.
- b) Dividir la cartera de clientes en distintos segmentos de comportamiento similar: Para los casos de grandes volúmenes de clientes precisaremos la asistencia de la Ciencia de datos, recurriendo a los métodos de *clustering* con aprendizaje automatizado como se describe *ut supra*.

Al tratarse de un agrupamiento no supervisado, la herramienta de DA podrá determinar distinta cantidad de *clusters*. Interpretándolo desde el punto de vista del objetivo analítico de negocio (comparando el valor percibido por los clientes *versus* los costos que se pueden ahorrar por el *unbundling* del complemento), la taxonomía de ellos puede permitir identificar conjuntos de *clusters* (CC) que denominaremos:

- i. CC de Clientes Extremo Superior (CCCES): *Clusters* conformados por clientes que abandonarán la cartera (si se trata de servicios recurrentes o abonados) o dejarán de adquirirlos (si se trata de compra de habitualidad) si se produjera el *unbundling*, independientemente del valor de descuento.
- ii. CC de Clientes Extremo Inferior (CCCEI): *Clusters* conformados por clientes que no abandonarán la cartera si se produjera el *unbundling*, independientemente del valor de descuento.

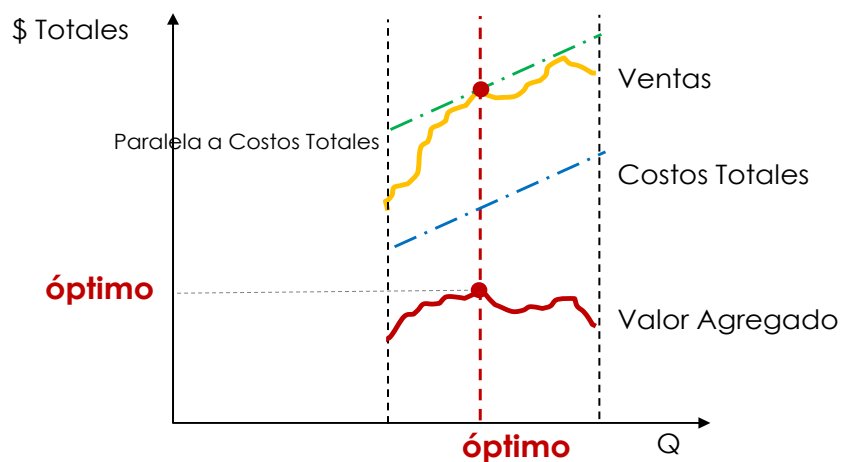
- iii. CC de Clientes Intermedios (CCCIx) *Clusters* conformados por clientes cuyo abandono de la cartera, si se produjera el *unbundling*, dependerá del valor de descuento a aplicar. En este caso, definiremos tantos conjuntos de clusters (empleando la x para identificarlos entre sí) como sean relevantes de acuerdo a lo que nos sugiera el modelo de DA elegido.

En paralelo, realizando el mismo análisis sobre potenciales clientes, que actualmente no lo son, pero podrán serlo si el precio del ofrecimiento desagregado lo convierte en atractivo, podremos identificar otros CC análogos a los CCCIx, que denominaremos CCPCx (CC de Potenciales Clientes)

Dado que la ponencia se focaliza en la determinación del precio óptimo asociado al *unbundling*, el primer caso (CCCES) no es foco de la presente ponencia. Sólo debe analizarse el impacto de los Costos Fijos recurrentes no hundidos para determinar la conveniencia de mantener el ofrecimiento original *versus* la aceptación de la fuga de estos clientes. Habitualmente los costos diferenciales (al no incluir los costos de única vez incurridos con anterioridad y por lo tanto hundidos) no son tan altos como para disparar la discontinuidad del combo *premium*, salvo que el conjunto de estos clientes sea muy reducido y no los pueda repagar.

Para cada uno los CC restantes (CCCEI, CCCIx y CCPCx), las herramientas de Ciencia de datos determinarán la relación precio-demanda del ofrecimiento desagregado (con *unbundling*) para predecir el comportamiento de compra en función del nivel de descuento (traslado de los ahorros de costo al precio) asumiendo que, dado el avance digital en los negocios, existe la posibilidad de llegada a los clientes y potenciales en forma de campañas 1-a-1 (en este caso se harán tantas campañas distintas como CC determinados) empleando las mejores estrategias de omnicanalidad digital utilizadas por las empresas.

Dada la precisión de las herramientas de DA (que se esmeran en determinar el algoritmo que mejor prediga y no en simplificar para el mejor entendimiento del lector) es de esperar que los algoritmos de la curva de ventas para cada uno de los *clusters* de comportamiento diferente no se representen con curvas cuadráticas negativas como el caso base de la elasticidad tradicional. Igualmente, para determinar el óptimo deben ser neteadas de costos totales dentro del rango analítico en forma análoga a lo expuesto *ut supra*. De igual manera, obtendremos la solución gráficamente con la paralela de los costos totales como se observa en la Gráfica #3:



Gráfica #3 – Elaboración propia

En este escenario, cada CC tendrá un precio óptimo diferente, Si no se lograra el aspiracional de n segmentaciones óptimas con canales de acceso 1-a-1 y se debiera determinar un único precio para el ofrecimiento con unbundling, se deberán sumar las distintas curvas de cada CCx para cada precio, y netearla de los costos totales para cada una de las cantidades resultantes de dichos precios.

7) MODELIZACIÓN SIMPLIFICADA

Si interviniéramos el modelo, saliéndonos de la ortodoxia de los modelos no supervisados para optimizar el entendimiento a sabiendas de un mayor grado de error matemático, podemos forzar la determinación de distintas elasticidades, una por cada CC analizada.

En el caso base se utiliza la variable elasticidad arco precio-demanda como constante sólo dentro del área analítica, de fórmula

$$\varepsilon^{\circ} = \frac{\frac{\delta q}{q^{\circ}}}{\frac{\delta p}{p^{\circ}}}$$

que, expresada en forma de algoritmo de cantidades en función del precio se representa, en el momento base, como

$$Q = k + (-x \cdot P)$$

En el ejemplo numérico planteado, la elasticidad -4 determinada para el momento 0 de precio=80\$/kg es:

$$Q = 500\text{kg} + (-5 \cdot P)$$

Y curva de ventas igual a:

$$V = 500\text{kg} \cdot P + (-5 \cdot P^2)$$

Interviniendo el modelo desarrollado *ut supra*, podemos forzar, para cada CC, un algoritmo lineal para expresar las cantidades en función del precio del momento base, del tipo

Expresión II

$$Q_n = k_n + (-x_n \cdot P_n)$$

Lo que significa un total de Costos Variables igual a:

Expresión III

$$CV_n = cv * [k_n + (-x_n \cdot P_n)]$$

y curva de ventas igual a:

Expresión IV

$$V_n = k_n \cdot P_n + (-x_n \cdot P_n^2)$$

Cuya representación gráfica es análoga a la presentada en la Gráfica #1, y la elasticidad precio demanda del momento base igual a:

Expresión V

$$\varepsilon_n = - \frac{(x_n \cdot P_n)}{Q_n}$$

7.1. Escenario de múltiples precios para el ofrecimiento desagregado

Si se trata del escenario de precios individualizados por CC por la aplicación de estrategias 1-a-1 digitalizadas, la fórmula para determinar la variación de precio óptima, por conjunto de *cluster* será:

$$\frac{\delta p}{P^o} = - \frac{\varepsilon^o - 1 + mc^o}{2}$$

Conocidos los algoritmos de Ventas (Expresión IV) y Costos variables totales (Expresión III), también se puede resolver utilizando planillas electrónicas con funcionalidad *Solver* de investigación operativa no lineal, dado que los objetivos a maximizar (CC por CC) surgirán de las n restas de las dos expresiones, todas ellas con comportamiento cuadrático.

7.2. Escenario de precio único para el ofrecimiento desagregado

En cambio, si se trata del escenario de determinar un precio único para el ofrecimiento con *unbundling* se deberá alimentar al *Solver* de investigación operativa no lineal con un único objetivo maximizador compuesto por:

- La suma de los n algoritmos de Ventas (Expresión IV)
- Neteada de los Costos Variables Totales, surgidos de la suma de las cantidades de cada CC (Expresión II) multiplicados por el costo variable unitario (que es el mismo para todos los casos)

Ejemplificamos con un caso de cuatro conjuntos de *clusters* (combinados entre clientes y potenciales) que cuentan con la siguiente información al momento base:

Conjunto de Cluster	Momento base			Algoritmo de relación precio demanda	
	Precio	Cantidad	Elasticidad	Pendiente	Raíz
I	100	1.400	-2,36	-33,00	4.700
II	100	2.000	-2,00	-40,00	6.000
III	100	1.180	-2,14	-25,20	3.700
IV	100	640	-4,00	-25,60	3.200

Utilizando la Expresión II, considerando las elasticidades de cada conjunto, las cantidades en función de precio (dentro del rango analítico) resultarán:

$$\begin{aligned} Q_I &= 4.700 + (-33 \cdot P_I) \\ Q_{II} &= 6.000 + (-40 \cdot P_{II}) \\ Q_{III} &= 3.700 + (-25,20 \cdot P_{III}) \\ Q_{IV} &= 3.200 + (-25,60 \cdot P_{IV}) \end{aligned}$$

Si la acción de *unbundling* lograra reducir el costo variable unitario a \$40, eligiendo como objetivo maximizador a la Contribución Marginal Total (dado que los Costos Fijos no serán diferenciales porque se deben mantener para el ofrecimiento no desagregado), se obtendría el siguiente resultado sin ninguna reducción de precio:

Conjunto de Cluster	Con reducción costo variable por unbundling					Contribución Marginal Total
	Precio	Cantidad	cvu	Ventas	CVT	
I	100,00	1.400	40,00	140.000	56.000	84.000
II	100,00	2.000	40,00	200.000	80.000	120.000
III	100,00	1.180	40,00	118.000	47.200	70.800
IV	100,00	640	40,00	64.000	25.600	38.400
Total		5.220		522.000	208.800	313.200

En su lugar, la aplicación del modelo no lineal de investigación operativa recomendará la reducción de un 8,92% del precio (nuevo precio \$91,08) que permitirá el siguiente incremento del volumen de ventas en función de las cuatro distintas elasticidades de cada CC:

$$\begin{aligned} Q_I &= 8,92\% \cdot 2,36 \\ &= \mathbf{21\%} \end{aligned}$$

$$\begin{aligned} Q_{II} &= 8,92\% \cdot 2 \\ &= \mathbf{17,8\%} \end{aligned}$$

$$\begin{aligned} Q_{III} &= 8,92\% \cdot 2,14 \\ &= \mathbf{19\%} \end{aligned}$$

$$\begin{aligned} Q_{IV} &= 8,92\% \cdot 4 \\ &= \mathbf{35,7\%} \end{aligned}$$

Dando un resultado óptimo, con un incremento de participación en el mercado del 21,15% y un aumento del valor agregado de 9.845 \$ (3,14%).

Conjunto de Cluster	Con reducción costo variable por unbundling					Contribución Marginal Total
	Precio	Cantidad	cvu	Ventas	CVT	
I	91,08	1.694,36	40,00	154.322	67.774	86.548
II	91,08	2.356,80	40,00	214.657	94.272	120.385
III	91,08	1.404,78	40,00	127.948	56.191	71.756
IV	91,08	868,35	40,00	79.090	34.734	44.355
Total		6.324,30		576.017	252.972	323.045
Incremento		1.104,30		54.017	44.172	9.845

8) CONCLUSIONES

El análisis llevado a cabo deja en evidencia que la técnica de Desagregación (*Unbundling*) de Mercadotecnia puede ser optimizada, tanto por la aplicación de enfoques y modelos de Gestión y Costos basados en la Teoría General de Costos con visión económica, incorporando la relación de precios con el comportamiento de la demanda cuanto por la precisión que aportan la Ciencia de Datos con sus herramientas de análisis de grupos con aprendizaje automatizado de predicción (*Clustering* con *machine learning*).

Los modelos permiten la determinación del mejor precio del nuevo ofrecimiento desagregado, considerando distintos escenarios de percepción de valor de segmentos de clientes y distintos modelos de relacionamiento con los mismos para realizar digitalmente los nuevos ofrecimientos

9) BIBLIOGRAFÍA

- (1) Porter (1985) "***The Competitive Advantage: Creating and Sustaining Superior Performance***". NY: Free Press, (Republished with a new introduction, 1998.)
- (2) Sharma (2020). "***Clustering vs Classification: Difference Between Clustering & Classification***". Publicado en <https://www.upgrad.com/blog/clustering-vs-classification/>

Se omiten las referencias de los autores