



**BANCO CENTRAL DE RESERVA DEL PERÚ**

# **Predicción del Riesgo de Crédito en el Sistema Financiero Peruano**

Diego Yamunaque\*, Miguel Cabello\*\* y  
Camila Rodríguez\*\*\*

\* Banco Central de Reserva del Perú

\*\* CUNEF Universidad.

\*\*\* Corporación Financiera Internacional

**DT. N°. 2024-015**

Serie de Documentos de Trabajo

Working Paper series

Diciembre 2024

Los puntos de vista expresados en este documento de trabajo corresponden a los de los autores y no reflejan necesariamente la posición del Banco Central de Reserva del Perú.

The views expressed in this paper are those of the authors and do not reflect necessarily the position of the Central Reserve Bank of Peru

# Predicción del Riesgo de Crédito en el Sistema Financiero Peruano

Diego Yamunaque

Miguel Cabello

Camila Rodríguez

Banco Central de Reserva del Perú CUNEF Universidad Corporación Financiera Internacional

24 de diciembre de 2024

## Resumen

Este estudio construye, de forma intuitiva, una medida de riesgo de crédito que captura el deterioro de una cartera de préstamos en estado normal en una ventana de 12 meses. De esta forma, corregimos los problemas y sesgos que tiene utilizar el ratio de morosidad como aproximación de la probabilidad de impago de los deudores del sistema financiero. Asimismo, utilizando diferentes técnicas de predicción univariada y multivariada, predecimos la senda futura (6 meses en adelante) de la probabilidad de impago. Los modelos con parámetros cambiantes en el tiempo muestran un mejor desempeño prediciendo el valor fuera de la muestra con relación a las predicciones derivadas de modelos con parámetros constantes en el tiempo para las predicciones de horizonte más largo. Cuando el horizonte es pequeño, las predicciones derivadas de los modelos con parámetros constantes muestran un desempeño bastante bueno.

## 1. Introducción

Es bastante común que las instituciones bancarias estén preocupadas por cuantificar la probabilidad de impago de un individuo o una firma a fin de medir el riesgo de crédito de estos agentes. Para los supervisores bancarios y macroprudenciales es importante tener a disposición una medida del riesgo de crédito y conocer diferentes escenarios de su evolución a futuro. Conocer la evolución futura de la probabilidad de impago es crucial, ya que proporciona a los supervisores bancarios una base sólida para decidir si deben aumentar o disminuir los requerimientos de capital de las entidades supervisadas, o fomentar la acumulación adicional de provisiones. En el caso del supervisor macroprudencial, el tener diversos escenarios de la evolución de probabilidad de impago es relevante para monitorear la exposición del sistema bancario, especialmente luego de que la economía peruana ha estado expuesta a un gran choque de demanda negativo producto de la crisis sanitaria. Asimismo, es importante poder relacionar la evolución de la probabilidad de impago a otras variables financieras o macroeconómicas, a fin de conocer como la evolución futura de la actividad económica pueda afectar la dinámica del riesgo de crédito.

Diversos trabajos han estudiado la relación entre la probabilidad de impago y variables como las condiciones de la deuda, características socioeconómicas, factores macroeconómicos o comportamiento financiero de los agentes. [Jimenez y Saurina \(2004\)](#) realizan un análisis empírico sobre los determinantes de la probabilidad de impago de créditos bancarios. Ellos encuentran que: (i) los créditos colateralizados tienen un mayor nivel de riesgo promedio; (ii) créditos otorgados por cajas de ahorro son más riesgosos; (iii) el apetito por riesgo se incrementa cuando la relación cliente-entidad es más cercana. Por otro lado, [Jimenez y Saurina \(2006\)](#) encuentran una relación negativa entre el horizonte de pago de un préstamo y la probabilidad de impago, sugiriendo que la probabilidad de impago para préstamos de largo plazo es baja debido al screening adecuado de

las instituciones bancarias. [Foglia y coautores \(1998\)](#) y [Fiordelisi y coautores \(2014\)](#) encuentran que mantener deudas con diversos bancos se asocia a mayor riesgo crediticio y, por ende, una mayor probabilidad de impago.

Los trabajos anteriores muestran la relación entre el riesgo de crédito (probabilidad de impago) de los clientes y sus características individuales, lo cual es necesario desde el punto de vista de una entidad financiera que busca monitorear el cumplimiento de las obligaciones de sus deudores. Sin embargo, desde el punto de vista de los reguladores bancarios o macroprudenciales, es relevante conocer la evolución de una medida de riesgo de crédito que capture la transición de una situación normal (no impago) hacia una de impago dentro de una ventana de tiempo para distintos segmentos de crédito que permitan identificar potenciales vulnerabilidades en el sistema financiero, lo que podría tener efectos sobre la economía real. En la literatura hay varios trabajos recientemente publicados que lidian con predecir el riesgo de crédito de transición para diferentes segmentos. [Dendramis, Tzavalis y coautores \(2020\)](#) modelizan el evento de impago (evento binario) para créditos de consumo en Grecia. Utilizando una metodología novedosa -funciones de enlace asimétricas-, encuentran que las variables macroeconómicas como PIB o desempleo son predictores relevantes, así como otras características específicas del cliente y el crédito. Asimismo, muestran que el introducir la función logit asimétrica mejora el desempeño de las predicciones fuera de muestra. [Kaposty, Kriebel y Loderbusch \(2020\)](#) estudian diferentes métodos de predicción (paramétricos y no paramétricos) para las pérdidas tras incumplimiento para una muestra de 1184 empresas corporativas en Alemania. Concluyen que los métodos tradicionales son más simples de implementar y fáciles de comunicar, mientras que los métodos de aprendizaje automático, como *Random Forest*, mejoran significativamente el poder predictivo. Además, encuentran que la actualización continua de la información incrementa la precisión de las predicciones. Por otro lado, factores como la exposición al impago, el tipo de activos y la industria resultan ser determinantes clave en la capacidad predictiva del modelo.

Para el caso peruano, [Bohorquez y coautores \(2017\)](#) utilizan el Reporte Crediticio de Deudores (RCC) y analizan el riesgo crediticio expost para los deudores que no estuvieron en situación de default al inicio de una ventana de evaluación de un año. A través de la estimación de modelos logit, los autores encuentran evidencia de una relación positiva entre la madurez de los préstamos y la probabilidad de impago de hogares o firmas. Sugieren que esta relación podría deberse a la presencia de informalidad en los deudores financieros peruanos. Por otro lado, encuentran que el efecto de los impulsores del riesgo crediticio (colateral y número de relaciones banco-deudor) varía dependiendo de la madurez del crédito.

Estos trabajos son bastante útiles, sin embargo no brindan una forma sencilla de como escenarios futuros sobre las variables macroeconómicas o financieras puedan utilizarse para predecir los valores futuros del riesgo de crédito agregado. Por ejemplo, en el caso del trabajo de [Dendramis, Tzavalis y coautores \(2020\)](#), si bien los autores obtienen predicciones a futuro (tres, seis y nueve meses) de la probabilidad de impago individual, esto se hace únicamente basándose en información histórica de los predictores. En el caso de querer ir hacia un horizonte de predicción más largo, esto se podría hacer únicamente utilizando información histórica más en el pasado, lo cual haría que nuestra predicción no pueda utilizar información nueva o escenarios diferentes para los predictores. Además, el obtener una predicción individual de la probabilidad de default introduce una nueva complejidad, que es la de agregar ello a niveles de segmentos o incluso para todo el sistema. Por ejemplo, es bastante común en las pruebas estrés que realizan los organismos supervisores y macroprudenciales, tener un escenario de referencia en el cual se establecen distintas niveles futuros de ratios de incumplimiento (ver [Budnik y coautores \(2019, 2020\)](#) y las referencias dentro de ambos documentos) por segmentos o agregados.

Por el contrario, los modelos que utilizan series temporales tienen como ventaja que pueden generar las predicciones de un sistema dinámico. Ello ayuda a que si las predicciones de riesgo de crédito dependan de la evolución futura del resto de predictores, podríamos generar esas

predicciones de forma directa utilizando el mismo sistema dinámico. Por ejemplo, [Hoggarth, Sorensen y Ziccino \(2005\)](#) emplean un modelo de vectores autoregresivos (VAR) para realizar un prueba de estrés macroeconómico del sistema bancario del Reino Unido. Los autores capturan la dinámica entre el ratio de créditos castigados sobre crédito total y variables macroeconómicas relevantes. Resaltan que la ventaja de emplear un modelo VAR es su capacidad predictiva de los cambios del ratio de créditos castigados, ya que se puede obtener un estimado de los cambios en el ratio de créditos castigados condicional a variables relevantes del ciclo económico.

Este trabajo, más que explicar los factores o posibles determinantes de la evolución del riesgo de crédito, se centra en estudiar la capacidad de distintos modelos dinámicos en predecir la evolución de la probabilidad de impago agregada o promedio de diferentes segmentos de crédito. Nuestra medida de riesgo de crédito no es la usualmente utilizada en la literatura, la cual suele emplear la proporción de cartera de crédito que está atrasada (tasa de *non-performing* o *delinquency*), sino que trata de recrear una situación en la cual se mide el deterioro del préstamo desde su originación. Así, nuestra medida captura el deterioro de una cartera de préstamos en situación normal en una ventana de 12 meses. De esta forma evitamos cualquier sesgo que podría causar el uso de sólo aquellos préstamos que otorgan en cada mes, ya que en un mes o periodo en particular se pueden otorgar menos créditos por diversos factores y ello no sería representativo de la cartera de crédito total del sistema.

Otra ventaja de nuestra medida, en comparación con el ratio de morosidad o *delinquency* es que, a diferencia de este último, que incluye todos los créditos atrasados en el momento actual sin distinguir si dichos préstamos ya estaban en situación de atraso desde hace meses, nuestra medida de impago se enfoca exclusivamente en el deterioro de aquella cartera que se encontraba en estado normal 12 meses antes. De esta forma evitamos una innecesaria persistencia en nuestro indicador. Aunque, como se verá más adelante, la persistencia en el nuevo indicador es notable. Nuestra medida de riesgo de crédito también puede interpretarse como una medida que captura la probabilidad de transición hacia el impago.

Respecto a los modelos de predicción empleados, nos hemos enfocado en métodos de series temporales, tanto univariantes como multivariantes. No hemos aplicado ningún método no paramétrico de aprendizaje automático como *regression trees* o *random forest* ya que estos métodos hacen uso intensivo de la información, y dada nuestra restricción en cuanto al número de periodos disponibles, esto podría causar cierta imprecisión en las predicciones. Sin embargo, reconocemos que esto es una tarea pendiente a realizar en un futuro relativamente cercano. Asimismo, como es común en la literatura de predicción, utilizar las predicciones de un solo modelo puede resultar ser peor, en términos de precisión, que si se combinan las distintas predicciones obtenidas por diferentes modelos (ver [Hsiao y Wan \(2014\)](#) y [Baumeister y Kilian \(2015\)](#)). Por tanto, también utilizaremos un promedio ponderado de las predicciones de cada modelo.

Así, podemos mostrar que algunos modelos multivariados mejoran, en ciertos casos, la precisión de los modelos univariados, especialmente si tienen regularización. Por otro lado, es importante señalar, que los modelos con parámetros cambiantes en el tiempo muestran un mejor desempeño cuando predicen fuera de muestra que los modelos con parámetros invariantes. Esto es de especial relevancia sobre todo en un contexto de alta incertumbre macroeconómica. Por otro lado, los modelos que se han desarrollado permiten al investigador proceder a calcular predicciones condicionadas. En este estudio hemos generado dichas predicciones de forma automática. Sin embargo, dichas predicciones sobre la evolución de las diferentes variables macroeconómicas, pueden ser provistas por un experto o por lo que la autoridad financiera considera plausible para dichas variables. Entonces, será posible generar predicciones de las medidas de riesgo en base a dichas sendas futuras. Esto es una gran ventaja en comparación a los modelos tipo caja negra, como son los de aprendizaje automático.

## 2. Variable de Interés y Resumen de Datos

### 2.1. Riesgo de Crédito

Sea  $S_{it}$  el saldo de crédito de determinado segmento de la unidad  $i$  (cliente-banco) en el período  $t$ . Asimismo,  $S_{it}^d$  denota el saldo de crédito con  $d$  o más días de atraso. Definimos la variable binaria  $y_{it}^d = \mathbf{1}(S_{it}^d > 0)$ , que toma el valor de 1 si para la unidad  $i$  presenta un saldo de crédito con  $d$  o más días de atraso en el periodo  $t$ . Así, la probabilidad de impago de la unidad  $i$  en el momento  $t$  la definimos como:

$$\pi_{it} = \mathbb{P}(y_{it}^{90} = 1 | y_{i,t-12}^0 = 0, \mathcal{I}_t), \quad (1)$$

donde  $\mathcal{I}_t$  representa el conjunto de información hasta el periodo  $t$ .

Es importante notar que en la definición de la probabilidad de impago se ha optado por una ventana de 12 meses (1 año), que es lo estándar en la literatura y la práctica regulatoria. Sin embargo, dependiendo de cuán *ácida* (exigente) queremos que sea la medida de riesgo de crédito, esta ventana puede acortarse a 6 o 3 meses. Asimismo, es relevante mencionar que solo nos fijamos en la evolución 12 meses después de la *originación*, si el crédito desapareciese entre  $t - 12$  y  $t$  por cualquier razón, la medida no estaría capturando dicho comportamiento. Sin embargo, no son muchos los casos en nuestra muestra en que un crédito en estado normal desaparece en los siguientes 12 meses.

En general, la probabilidad de impago  $\pi_{it}$  es heterogénea a nivel individual y a través del tiempo. Asimismo, puede resultar de poca utilidad conocer la probabilidad de transición de un individuo o firma en particular para fines macroprudenciales, ya que, como se ha mencionado antes, es más relevante conocer lo que ocurre con un segmento o un grupo de créditos más que con uno en particular. Es por ello que en lugar de predecir una senda futura para la probabilidad de impago individual, hemos optado por predecir el valor promedio de dicha medida de riesgo de crédito. La probabilidad promedio o agregada se define como:

$$\pi_t = \int_{\mathcal{J}} \pi_{it} dG_t(i) \quad (2)$$

donde  $G_t(i)$  representa el peso (ponderación) para la unidad de análisis  $i$  en el periodo  $t$  y  $\mathcal{J}$  representa la población total de individuos. En este sentido, nuestra medida de riesgo de crédito representa un promedio ponderado de las probabilidades individuales.

Se pueden plantear diferentes medidas de probabilidad agregada dependiendo de la ponderación elegida. Una forma intuitiva y bastante simple es la de ponderar cada unidad equitativamente, en este caso el ponderador elegido es  $1/n$ , donde  $n$  representa a la cantidad total de unidades en un determinado segmento o en el sistema.

$$\hat{\pi}_t = \sum_i \pi_{it} \times \frac{1}{n}.$$

En la medida anterior se asume que las unidades que empiezan en  $t - 12$  son las mismas a las que acaban en  $t$ . En caso de que existan unidades de análisis que aparecen al final de la ventana, podemos utilizar una medida que solo tome en cuenta las unidades que empiezan en  $t - 12$ . Si definimos  $n_{t-12} = \sum_i \mathbf{1}(S_{i,t-12} \neq \cdot) \mathbf{1}(y_{i,t-12}^0 = 0)$ , donde  $\mathbf{1}(S_{i,t-12} \neq \cdot)$  identifica si la unidad actual ha estado en  $t - 12$  o no, entonces:

$$\hat{\pi}_t = \sum_i \pi_{it} \times \frac{\mathbf{1}(S_{i,t-12} \neq \cdot)}{n_{t-12}}.$$

Lo anterior asume que la probabilidad de impago es observable. Sin embargo, no lo es; por tanto se requiere un estimador. Uno sencillo e intuitivo es  $\mathbf{1}(y_{it}^{90} = 1) \mathbf{1}(y_{it-12}^0 = 0)$ , cuya media condicional en empezar  $t - 12$  sin atraso es igual a nuestra medida de riesgo de crédito individual.

$$\hat{\pi}_t = \sum_i \omega_{it} \mathbf{1}(y_{it}^{90} = 1) \mathbf{1}(y_{it-12}^0 = 0)$$

Una ponderación usualmente utilizada en la literatura es la proporción de cartera crédito que está en condición de atraso. Tomando  $\omega_{it} = \frac{S_{it}^{90} \mathbf{1}(S_{i,t-12} \neq \cdot) \mathbf{1}(y_{it-12}^0 = 0)}{\sum_i S_{it} \mathbf{1}(S_{i,t-12} \neq \cdot) \mathbf{1}(y_{it-12}^0 = 0)}$ , se tiene:

$$\hat{\pi}_t = \sum_i \frac{S_{it}^{90} \mathbf{1}(S_{i,t-12} \neq \cdot) \mathbf{1}(y_{it-12}^0 = 0)}{\sum_i S_{it} \mathbf{1}(S_{i,t-12} \neq \cdot) \mathbf{1}(y_{it-12}^0 = 0)} \times \mathbf{1}(y_{it}^{90} = 1) \mathbf{1}(y_{it-12}^0 = 0). \quad (3)$$

Todavía es un tema abierto determinar cuán precisas son estas distintas medidas del verdadero valor del riesgo de crédito agregado. En cualquier caso, utilizaremos esta última como nuestra medida de riesgo de crédito agregado, ya que pondera cada unidad según la proporción que representa su saldo de crédito en el sistema. De esta forma, si un deudor grande (una unidad con saldo de crédito significativo) entra en impago, su importancia relativa será menor que la que pueda tener si entra en impago una unidad o cliente pequeño (con un saldo de crédito poco importante).

Por otro lado, el ratio de morosidad o *delinquency* es:

$$\text{Morosidad} = \sum_i \frac{S_{it}^{90}}{\sum_i S_{it}} \mathbf{1}(y_{it}^{90} = 1).$$

Comparando este ratio con nuestra medida de riesgo de crédito,  $\hat{\pi}_t$ , se puede notar rápidamente que en nuestro caso restringimos solo a los créditos que al inicio de la ventana de 12 meses (en el momento de la *originación*) no presentan atrasos. De esta forma, se estaría capturando el deterioro de la cartera de préstamos en la venta. Al contrario, con el indicador de cartera morosa no restringimos la ventana de análisis, por tanto solo estaríamos capturando la probabilidad de deterioro incondicional, es decir, el deterioro en todas las ventanas de análisis posibles. Por lo que esta medida puede dar una información imprecisa cuando se quiere monitorear el deterioro de una cartera de crédito en momentos de alta incertidumbre.

Por otro lado, a diferencia de un estimador de *cosechas*, que sólo considera créditos verdaderamente otorgados en  $t - 12$ , nuestro indicador considera a todos los créditos en situación normal en  $t - 12$ . Esto hace que nuestra medida de riesgo de crédito sea representativa y facilita su predicción, ya que una medida basada únicamente en créditos nuevos puede presentar un componente estacional relevante.

## 2.2. Datos

En este trabajo utilizamos dos fuentes de información. Por un lado, la información necesaria para la construcción de nuestra medida de riesgo de crédito ha sido obtenida del *Reporte Consolidado de Créditos* (RCC), la cual es un registro de créditos que contiene información detallada del saldo de préstamos otorgados por un banco a un cliente en un periodo determinado, así como el saldo en condición de impago. Por otro lado, los datos adicionales relacionados con la actividad económica y las variables financieras han sido obtenidos de la base de datos de *Series Estadísticas* del Banco Central de Reserva del Perú (BCRP).

Además, a pesar que estemos interesados en predecir una medida agregada de riesgo de crédito; sí es relevante poder distinguir diferentes segmentos, ya que el comportamiento y evolución de

los préstamos hipotecarios es diferente de los créditos para empresas corporativas o medianas. Específicamente, nos centramos en diferencias dos grandes grupos: créditos de consumo e hipotecario y créditos a empresas. Dentro del primer grupo distinguimos los segmentos de créditos revolventes (tarjetas de crédito), no revolvente (créditos de consumo comunes) y créditos hipotecarios. En el segundo grupo, consideramos tres segmentos: crédito mayorista, que incluye financiamiento para corporativos y grandes empresas; crédito a empresas medianas; y créditos a mypes (pequeñas y microempresas).

Respecto al período analizado, hemos tomado información desde enero de 2012, que es el primer período donde podemos construir nuestra medida de riesgo de crédito para los distintos segmentos considerados antes, hasta junio de 2023. Esto implica que tenemos un total de 138 observaciones.

### 2.3. Créditos e Impago

En la Figura 1 se puede apreciar la evolución de nuestra medida de riesgo de crédito para los diferentes segmentos del grupo de créditos de consumo e hipotecario. En la primera columna de la gráfica se puede notar que el riesgo de crédito para los tres segmentos (revolvente, no revolvente e hipotecario) han ido creciendo de forma sostenida desde enero de 2012, aunque para el caso del riesgo de crédito para los préstamos no revolventes se observa una estabilización a partir del 2017. Con la crisis sanitaria del COVID-19, el riesgo de crédito para los tres segmentos presenta una reducción significativa hasta la mitad de 2020, aproximadamente, luego de lo cual se presenta un incremento muy rápido en el riesgo de crédito de dichos segmentos hasta la mitad de 2021, aproximadamente. Después de ello se nota una reversión pronunciada a niveles previos a la crisis sanitaria. En los últimos 18 meses se ha aprecia una recuperación sostenida en el riesgo de crédito para todos los segmentos.

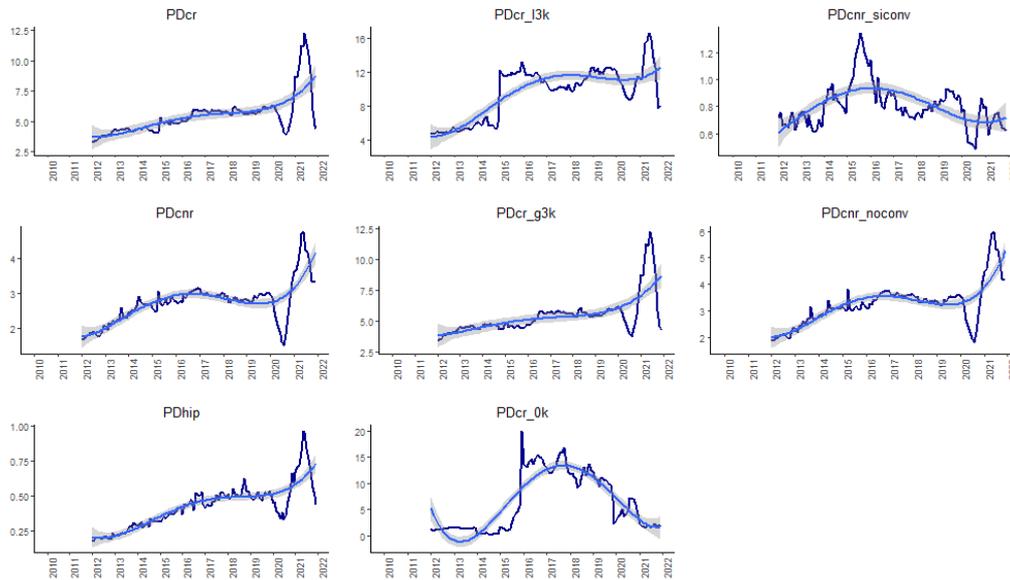
Dentro del segmento de préstamos revolventes hemos realizado un desagregamiento por tamaño de línea de crédito: un grupo de línea de crédito mayor a tres mil soles, otro con línea de crédito menor a tres mil soles y un tercer sub-segmento de créditos cuya línea de crédito ha sido suspendida, a la que hemos llamado como créditos sin línea. En la segunda columna de la Figura 1 muestra la evolución de estos tres sub-segmentos de préstamos revolvente. Se puede apreciar que el riesgo de crédito para el segmento con línea mayor a 3 mil soles presenta niveles y una evolución bastante similar al del segmento agregado de préstamos revolventes. El riesgo de crédito para préstamos con línea inferior a 3 mil soles presenta un salto importante al inicio de 2015, alrededor de 6 puntos porcentuales, luego se estabiliza alrededor de un nivel de 12%. Finalmente, el riesgo de impago para préstamos sin línea de crédito presenta una evolución muy diferente al agregado: presenta un salto en la mitad del 2015 de alrededor de 17 puntos porcentuales, luego de ello ha mostrado una tendencia decreciente.

Para el caso de préstamos no revolventes, se ha dividido en dos sub-segmentos: préstamos con convenio y sin convenio. En la tercera columna de la Figura 1 se puede apreciar la evolución de ambos sub-segmentos de crédito no revolvente. El riesgo crediticio de los préstamos sin convenio tienen una trayectoria muy similar al riesgo de crédito no revolvente agregado. Por el contrario, el riesgo crediticio de los préstamos con convenio tienen una evolución más volátil, fluctuando alrededor de una media de 0,8%, con una tendencia claramente decreciente entre 2015 y 2022.

Por otro lado, el comportamiento de los ratios de impago para créditos de consumo revolvente y no revolvente pueden presentar heterogeneidad a nivel de sub-segmentos. En el caso de crédito de consumo revolvente desagregamos por tamaño de línea de crédito: (i) sin línea de crédito, (ii) con línea de crédito menor a tres mil soles, y (iii) con línea de crédito mayor a tres mil soles. El impago de créditos revolvente para línea de crédito mayor a tres mil soles muestra un nivel y una evolución muy similar al agregado de crédito revolvente. En cuanto al impago de créditos revolvente con líneas de créditos menor a tres mil soles, se aprecia un salto en el nivel promedio

después de 2014. Específicamente, entre 2012 y 2014, el nivel promedio es alrededor de seis por ciento, mientras que para después del 2015 hasta el 2022, el nivel promedio es alrededor de 12 por ciento.

Figura 1: Riesgo de Crédito para Préstamos de Consumo e Hipotecario



En la primera columna, los gráficos corresponden a las probabilidades de incumplimiento (azul oscuro) y su respectivo filtro de Hodrick-Prescott (azul claro) de los segmentos de consumo revolvente, no revolvente e hipotecario, respectivamente. La segunda columna los muestra para el segmento de consumo revolvente para clientes con líneas de crédito menores o iguales y mayores a S/ 3 000, así como para aquellos que no reportan línea de crédito, respectivamente. Finalmente, la tercera columna hace lo propio para el segmento de consumo no revolvente, según si el crédito fue otorgado por convenio (descuento en planilla) o no, respectivamente.

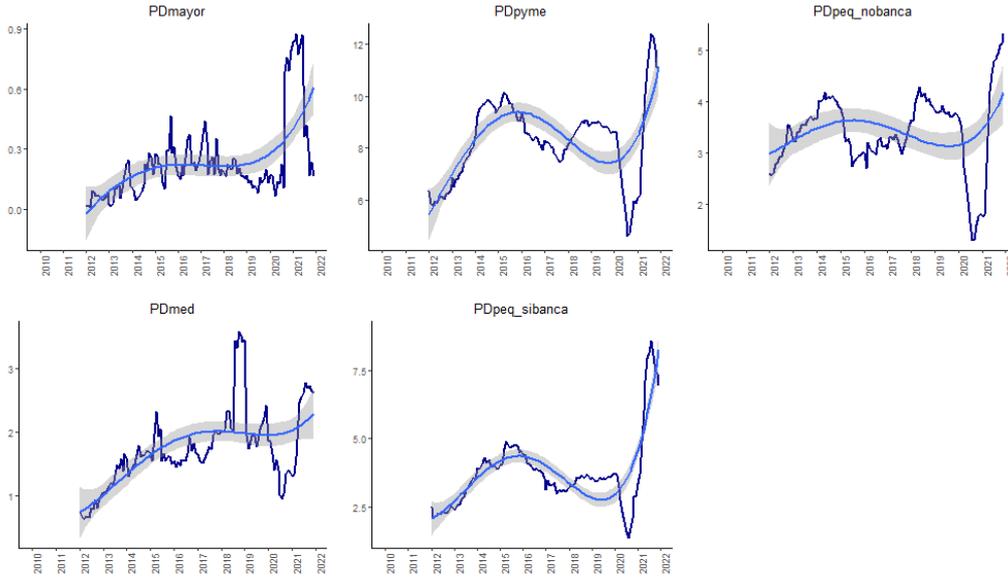
La Figura 2 muestra la evolución de nuestra medida de riesgo de crédito para préstamos a empresas. En el caso del riesgo de crédito para empresas del segmento mayorista, se puede apreciar que, en general, el riesgo crediticio está bastante acotado y ha sido inferior al 1% en todo el período de análisis. Asimismo, se observa un comportamiento diferenciado antes y después de la pandemia. Hasta antes del 2020, el riesgo crediticio de este segmento mostró un comportamiento en el que su nivel se incrementó hasta cierto punto máximo alcanzado entre 2015 y 2017, luego de lo cual empezó a descender. Sin embargo, a partir del 2020, y contrario a lo observado en el riesgo crediticio para préstamos personales, se observa un salto en el que el nivel se multiplicó por más del cuádruple hasta la mitad de 2021, para posteriormente revertir a niveles similares pre-pandemia.

En el caso de la medida de riesgo crediticio para préstamos a medianas empresas, se observa un crecimiento sostenido entre 2012 y 2015 en la que la probabilidad agregada de impago se duplicó. Entre 2015 y 2018, el nivel de riesgo de crédito se estabilizó alrededor del 1,5%. Sin embargo, entre 2018 y 2019 se aprecia un incremento significativo (el nivel se más que duplicó). A diferencia de la medida de probabilidad de impago para empresas mayoristas, se observa una reducción del riesgo de crédito en el 2020, mientras que desde 2021 se puede observar una corrección al alza.

Para el crédito a Pymes, nuestra medida de probabilidad de impago muestra un comportamiento bastante marcado entre etapas. Entre 2012 y 2015, se aprecia un crecimiento sostenido del riesgo de crédito de Pymes, en el que pasó de alrededor de 6% hasta un máximo de aproximadamente 10%. Luego, entre 2015 y mitad de 2017, se observa una caída sostenida en el impago de este tipo de préstamos, llegando hasta un nivel alrededor de 7,5%. Por otro lado, al igual que el riesgo de impago de los préstamos a empresas medianas, se produjo una reducción importante desde finales de 2019 hasta la mitad de 2020, aproximadamente; luego se produce una corrección fuerte al alza.

Finalmente, al igual que en el caso de créditos personales de consumo, hemos considerado dos segmentos más reducidos como son el de los préstamos a pequeñas empresas mediante bancos y otro otorgados por no bancos (cajas y otras organizaciones). El segmento de créditos a pequeñas empresas otorgados por entidades bancarias tiene una medida de riesgo crediticio bastante similar al del agregado de riesgo para préstamos a pymes. En el caso del riesgo a préstamos otorgados por entidades no bancarias, el comportamiento es similar, salvo porque la corrección al alza empieza no en 2017, sino dos años antes.

Figura 2: Riesgo de Crédito para Préstamos a Empresas



En la primera columna, los gráficos corresponden a las probabilidades de incumplimiento (azul oscuro) y su respectivo filtro de Hodrick- Prescott (azul claro) de los segmentos de mayoristas (Corporativo y gran empresa) y mediana empresa, respectivamente. La segunda columna los muestra para mypes (pequeña y microempresas), y para pequeñas empresas en sus créditos con las empresas bancarias, respectivamente. Finalmente, la tercera columna hace lo propio para las pequeñas empresas en sus créditos con las empresas no bancarias.

### 3. Metodología de Predicción

Hemos considerados modelos de predicción tanto univariados como multivariados. En el caso de modelos univariados se ha modelizado nuestra variable de interés como un proceso ARIMA, incluyendo diferentes componentes determinísticos. En el caso de modelos de predicción multivariados, se ha considerado un modelo de vectores autoregresivos. Aunque dependiendo del tipo de riesgo de crédito, se han incluido un diferente conjunto de predictores adicionales en el vector de variables endógenas.

#### 3.1. Variable Objetivo

Nuestra medida de riesgo de crédito agregada es, en esencia, una proporción, cuyo rango se encuentra en el intervalo  $[0, 1]$ . Como nuestros modelos de predicción son lineales, las predicciones basadas en este tipo de están expuestas a que el efecto parcial de los regresores sea constante y homogéneo. Esto lleva a que los valores predichos puedan caer fuera del intervalo  $[0, 1]$ . Para evitar ello, realizamos una transformación bastante común en modelos de regresión logística, que es tomar el logaritmo del *ratio odd* o ratio de probabilidades. Así, nuestra variable objetivo es:

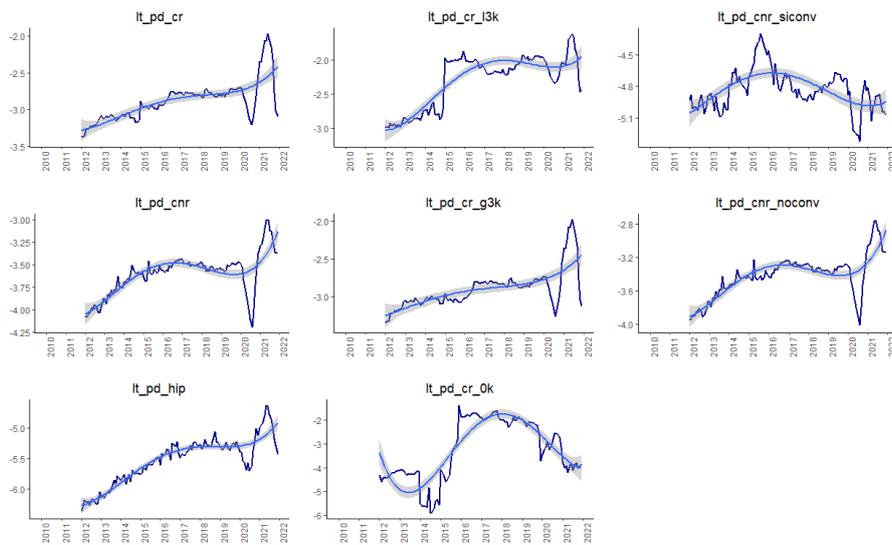
$$y_t = \log \left( \frac{\hat{\pi}_t}{1 - \hat{\pi}_t} \right) \quad (4)$$

De esta forma, una predicción de  $h$  períodos adelante, denotado por  $\hat{\pi}_{t+h|t}$ , se obtiene a partir de la predicción de  $h$  períodos adelante de  $\hat{y}_{t+h|t}$  usando la siguiente fórmula:

$$\hat{\pi}_{t+h|t} = \frac{\exp(\hat{y}_{t+h|t})}{1 + \exp(\hat{y}_{t+h|t})} \quad (5)$$

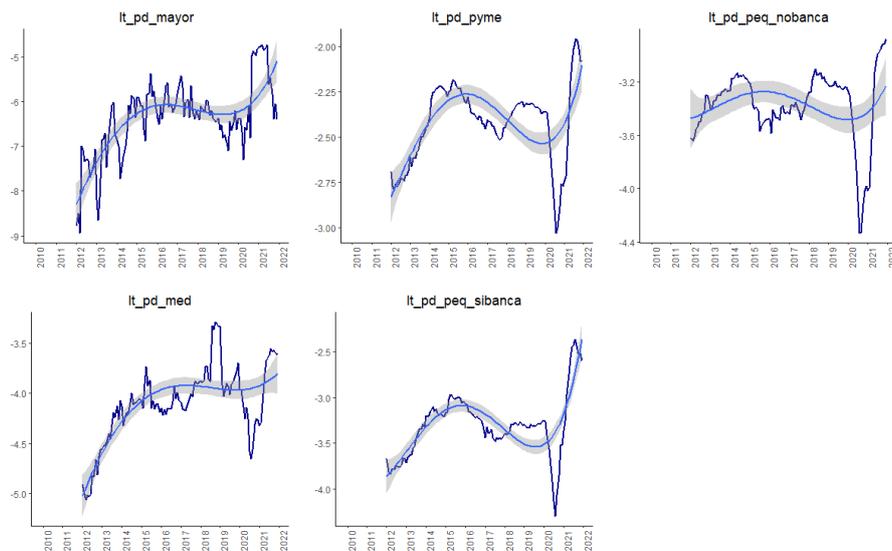
Cabe mencionar que este tipo de transformación es monótonica, es decir, que no cambia la dirección de ninguna de las trayectorias de riesgo de crédito. Las siguientes dos figuras muestran la evolución de estas transformaciones. Se puede apreciar que las trayectorias de las variables transformadas son bastante similares a las del riesgo de crédito sin transformar.

Figura 3: Transformación monótonica del Riesgo de Crédito para préstamos personales



El orden de los gráficos es similar al de la figura 1 (ver nota respectiva).

Figura 4: Transformación monótonica del Riesgo de Crédito para préstamos a empresas



El orden de los gráficos es similar al de la figura 2 (ver nota respectiva).

### 3.2. Modelos Univariados

Los modelos univariados que empleamos para estudiar la dinámica de  $y_t$  son del tipo *ARIMA*( $p, d, 0$ ), donde  $d$  representa el número de veces que se es necesario diferenciar la serie para obtener una serie estacionaria, también conocido como el orden de integración de  $y_t$  y denotado por  $\Delta^d y_t$ ;  $p$  representa el orden del modelo autoregresivo para  $\Delta^d y_t$ .

En términos formales, el modelo ARIMA para  $y_t$  es:

$$\phi(L, p)\Delta^d y_t = \delta(t) + u_t, \quad t = 0, 1, 2, \dots; \quad (6)$$

con  $u_t \sim WN(0, \sigma_u^2)$  el error de predicción de modelo y  $\delta(t)$  representa el componente determinístico de la serie  $\Delta^d y_t$ .

Hemos considerado dos posibles valores para el orden de integración:  $d \in \{0, 1\}$ . Cuando  $d = 0$ , la serie  $y_t$  entra en niveles (sin tomar primeras diferencias). En cambio, si  $d = 1$ , la variable a predecir es  $\Delta y_t$ .  $\phi(L, p)$  es un polinomio de retardos de orden  $p$ , con raíces fuera del círculo unitario, es decir, que  $\phi(L, p)$  genera soluciones estables. Dependiendo del tipo de componente determinístico que se permita, tendremos un modelo de predicción univariado diferente. En este documento hemos considerado cuatro formas para el componente determinístico: (i) constante; (ii) lineal; (iii) cuadrático; y (iv) cúbico. Por tanto, tendremos 4 modelos univariados diferentes. Dependiendo del tipo de componente determinístico, el orden de integración  $d$  estimado puede cambiar.

Utilizando un conjunto de información univariada  $\mathcal{I}_T^U = \{y_T, y_{T-1}, \dots, y_1\}$ , podemos construir la predicción  $h$  períodos adelante de la siguiente forma:

1. Si  $d = 0$  y con  $\phi(L, p) = 1 - \sum_{j=1}^p \phi_j L^j$ , entonces:

$$y_{T+h|T} = \delta(T+h) + \phi_1 y_{T+h-1|T} + \dots + \phi_p y_{T+h-p|T}.$$

2. Si  $d = 1$  y con  $\phi(L, p) = 1 - \sum_{j=1}^p \phi_j L^j$ , entonces:

$$\Delta y_{T+h|T} = \delta(T+h) + \phi_1 \Delta y_{T+h-1|T} + \dots + \phi_p \Delta y_{T+h-p|T}.$$

y para el nivel se tiene:

$$\begin{aligned} y_{T+1|T} &= y_T + \Delta y_{T+1|T} \\ y_{T+2|T} &= y_T + \Delta y_{T+2|T} + \Delta y_{T+1|T} \\ &\vdots \\ y_{T+h|T} &= y_T + \Delta y_{T+h|T} + \Delta y_{T+h-1|T} + \dots + \Delta y_{T+1|T} \end{aligned}$$

### 3.3. Modelos Multivariados

El análisis univariado es bastante útil, particularmente porque brinda un modelo de referencia que emplea solo información de nuestra variable de interés. Sin embargo, podemos obtener ganancias en cuanto a precisión de la predicción cuando se emplea información adicional. Específicamente, utilizaremos información adicional sobre variables macroeconómicas y financieras, tales como indicadores de actividad económica, precios de materias primas, entre otros. Toda la información adicional se encuentra contenida en el vector  $z_t$ .

#### 3.3.1. Modelos VAR estacionarios

La variable de interés puede entrar en primeras diferencias o en niveles. La elección del tipo de transformación dependerá de si la serie, en la muestra disponible, presenta evidencia de tener

un comportamiento no estacionario. En cualquier caso, la variable de interés (en diferencias o en niveles) junto con el conjunto de variables adicionales están contenidas en el vector  $\mathbf{x}_t$ . El modelo autoregresivo será de la forma:

$$\Phi(L, p)\mathbf{x}_t = \delta(t) + \mathbf{u}_t \quad (7)$$

donde  $\Phi(L, p)$  es un polinomio matricial de retardos de orden  $p$ , y como en el caso univariado las raíces del polinomio característico asociado a este polinomio deben estar fuera del círculo unitario, es decir que  $\det(\Phi(\lambda, p)) \neq 0$  para cualquier valor  $\lambda \in \mathbb{C}$  y  $|\lambda| < 1$ . El vector  $\mathbf{u}_t$  es un ruido blanco multivariado de media cero y con componentes mutuamente incorrelados, lo que se puede representar como  $\mathbf{u}_t \sim WN(\mathbf{0}, \Omega)$  con  $\Omega = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$  y  $n$  la dimensión de  $\mathbf{x}_t$ .

Asumiendo que el primer elemento del vector  $\mathbf{x}_t$  es la variable de interés, ya sea en niveles o en diferencias, la predicción  $h$  períodos adelante es:

1. Con variable de interés en niveles:

$$y_{T+h|T} = \delta_1(T+h) + [\Phi_1]_1 \mathbf{x}_{T+h-1|T} + \dots + [\Phi_p]_1 \mathbf{x}_{T+h-p|T},$$

donde  $[\Phi_j]_1$  es la primera fila de la matriz  $\Phi_j$  para  $j = 1, 2, \dots, p$ .

2. Con variable de interés en diferencias:

$$\Delta y_{T+h|T} = \delta_1(T+h) + [\Phi_1]_1 \mathbf{x}_{T+h-1|T} + \dots + [\Phi_p]_1 \mathbf{x}_{T+h-p|T},$$

y

$$\begin{aligned} y_{T+1|T} &= y_T + \Delta y_{T+1|T} \\ y_{T+2|T} &= y_T + \Delta y_{T+2|T} + \Delta y_{T+1|T} \\ &\vdots \\ y_{T+h|T} &= y_T + \Delta y_{T+h|T} + \Delta y_{T+h-1|T} + \dots + \Delta y_{T+1|T}. \end{aligned}$$

### 3.3.2. Modelos VAR integrados

Cuando existe una relación de largo plazo entre variables de un vector de variables endógenas, utilizar un modelo VAR utilizando primeras diferencias de las variables endógenas es útil pero, se pierde información, ya que las primeras diferencias tienden a tener mayor ruido idiosincrático y no se explota al completo la relación de largo plazo entre las variables. Por ello, puede resultar útil estimar un modelo VAR en niveles, basado en un vector de corrección de errores (VECM). De acuerdo con el trabajo de [Engle y Granger \(1987\)](#) y [Johansen \(1988\)](#), el modelo VECM es el siguiente:

$$\begin{aligned} \mathbf{y}_t &= \Phi_1 \mathbf{y}_{t-1} + \dots + \Phi_p \mathbf{y}_{t-p} + \mathbf{u}_t, \\ \Delta \mathbf{y}_t &= \Pi \mathbf{y}_{t-1} + \Phi_1^* \Delta \mathbf{y}_{t-1} + \dots + \Phi_{p-1}^* \Delta \mathbf{y}_{t-(p-1)} + \mathbf{u}_t; \end{aligned} \quad (8)$$

con  $\Phi_i^* = -\sum_{j=i+1}^p \Phi_j$  para  $i = 1, \dots, p-1$ ,  $\Pi = -(I - \Phi_1 - \dots - \Phi_p)$  y  $\mathbf{u}$  un proceso de ruido blanco multivariado.

Desafortunadamente, este tipo de modelos sólo es estimado considerando únicamente a las medidas de riesgo de crédito. Previamente a utilizar esta alternativa, es necesario verificar empíricamente que exista una relación de cointegración entre las variables del vector  $\mathbf{y}_t$ . La predicción se construye utilizando el modelo VAR sin diferenciar.

### 3.3.3. Modelos VAR regularizados

Uno de los problemas de los modelos VAR es que el número de parámetros crece a una tasa de  $n^2$  por cada retardo que se incluye, lo que hace necesario un alto número de observaciones para la precisión de la estimación. Sin embargo, muchos de los parámetros pueden resultar no relevantes, por lo que podría ser importante tener una forma de imponer dichos ceros al mismo tiempo de la estimación. Una forma de imponer dichas restricciones puede ser la de realizar pruebas de causalidad a lo Granger, no obstante ello puede resultar poco eficiente dado que se tendría que realizar una prueba por cada variable. Una forma alternativa para abordar la alta dimensionalidad es el método LASSO, propuesto inicialmente por Tibshirani (1996). Este método consiste en adicionar una restricción al problema de mínimos cuadrados ordinarios sobre los parámetros, esta consiste en restringir la norma  $L_1$  del vector de parámetros a cero.

El modelo VAR se puede expresar como un sistema de ecuaciones multivariado. De acuerdo con Kock y Callot (2012),  $i$ -ésima ecuación del modelo VAR se escribe como:

$$x_{t,i} = \mathbf{X}'_t \phi_i^* + u_{t,i}, \quad i = 1, 2, \dots, n; \quad t = 1, 2, \dots, T;$$

con  $\mathbf{X}_t = (\mathbf{x}'_{t-1} \ \dots \ \mathbf{x}'_{t-p})'$  y  $\phi_i^*$  es un vector  $np \times 1$ .

Para cada variable  $i$ , podemos agrupar las ecuaciones para todos los periodos disponibles de la siguiente forma:

$$\mathbf{x}_i = \mathbf{X} \phi_i^* + \mathbf{u}_i, \quad i = 1, 2, \dots, n;$$

con  $\mathbf{x}_i = (x_{T,i} \ x_{T-1,i} \ \dots \ x_{p+1,i})$  y  $\mathbf{X} = (\mathbf{X}_T \ \mathbf{X}_{T-1} \ \dots \ \mathbf{X}_{p+1})'$ .

Finalmente, si agrupamos las ecuaciones para todas las variables  $i$ , tenemos:

$$\mathbf{x} = \mathbf{Z} \phi^* + \mathbf{u}, \tag{9}$$

donde  $\mathbf{x} = [\mathbf{x}'_1 \ \mathbf{x}'_2 \ \dots \ \mathbf{x}'_n]'$ ,  $\mathbf{Z} = \mathbf{I}_n \otimes \mathbf{X}$  y  $\phi^* = (\phi_1^{*'} \ \phi_2^{*'} \ \dots \ \phi_n^{*'})'$ .

El estimador LASSO,  $\hat{\phi}_{LASSO}$ , se define como:

$$\hat{\phi}_{LASSO} = \arg \min_{\phi^*} \left( \|\mathbf{x} - \mathbf{Z} \phi^*\|^2 + \zeta_T \sum_{i=1}^{n^2 p} |\phi_i^*| \right) \tag{10}$$

Alternativamente, el estimador *adaptive*-LASSO,  $\hat{\phi}_{aLASSO}$ , se define como:

$$\hat{\phi}_{aLASSO} = \arg \min_{\phi^*} \left( \|\mathbf{x} - \mathbf{Z} \phi^*\|^2 + \zeta_T \sum_{i=1}^{n^2 p} \hat{\omega}_i |\phi_i^*| \right) \tag{11}$$

con  $\hat{\omega}_i$  es un peso o ponderación definido como  $\hat{\omega}_i = |\hat{\phi}_{I,i}|^{-\gamma}$  con  $\gamma > 0$  y  $\hat{\phi}_I$  es un estimador  $\sqrt{T}$ -consistente de  $\phi^*$ .

### 3.4. Combinación de Predicciones

Baumeister y Kilian (2015) y Hsiao y Wan (2014) encuentran que en muchas ocasiones un modelo de predicción particular puede generar predicciones sesgadas o sólo ser útil prediciendo solo algunos horizontes de predicción. Por tanto, centrarnos en elegir el mejor modelo de predicción, aunque es común, puede resultar ser poco recomendable, ya que en algunos casos podríamos elegir a un modelo de un grupo de modelos poco precisos. Por el contrario, podemos optar por utilizar todas las predicciones disponibles y construir una predicción híbrida, que

consiste en un promedio ponderado de las distintas predicciones. Esto puede reducir la varianza de las predicciones y con ello, mejorar la precisión. Sea  $y_{T+h|T}^m$  a la  $m$ -ésima predicción  $h$  períodos adelante de la variable  $y_t$ . Asumiendo que se dispone de una secuencia de predicciones no colineales  $\{y_{T+h|T}^m\}_{m=1}^M$ , entonces la predicción combinada es

$$y_{T+h|T}^* = \mathbf{w}' \mathbf{y}_{T+h|T} = [w_1 \quad w_2 \quad \cdots \quad w_M] \begin{bmatrix} y_{T+h|T}^1 \\ y_{T+h|T}^2 \\ \vdots \\ y_{T+h|T}^M \end{bmatrix}$$

La elección de pesos o ponderaciones puede hacerse de distintas formas:

1. **Promedio simple:** Una forma sencilla es considerar  $w_m = \frac{1}{M}$ .
2. **Regresión:** Para un horizonte de predicción fija  $h$ , si se tiene  $T_h$  predicciones, entonces los ponderadores pueden encontrarse de la siguiente forma

$$y_t = \alpha_0 + \mathbf{w}' \mathbf{y}_{T+h|T,t} + u_t$$

3. **Ponderador inverso al MSE** específico para horizonte  $h$ : Sea  $\hat{\sigma}_{h,m}^2$  el MSE del horizonte de predicción  $h$  del modelo  $m$ , el peso para construir el promedio de predicción para el horizonte  $h$  es

$$w_{m,h} = \frac{\hat{\sigma}_{h,m}^{-2}}{\sum_{m=1}^M \hat{\sigma}_{h,m}^{-2}}$$

4. **Ponderador inverso al MSE:** Sea  $\hat{\sigma}_m^2$  el MSE del horizonte de predicción del modelo  $m$ , el peso para construir el promedio es

$$w_m = \frac{\hat{\sigma}_m^{-2}}{\sum_{m=1}^M \hat{\sigma}_m^{-2}}$$

## 4. Resultados

### 4.1. Análisis Previo

La Tabla 1 muestra el resultado de las pruebas de raíz unitaria para la transformación logística del riesgo de crédito. Se han considerado seis diferentes pruebas de raíz unitaria, todas tienen en común que la hipótesis nula es que la serie presenta una raíz unitaria, sin embargo, si difieren en cuanto al tipo de componente determinístico. Por ejemplo, la prueba de Schmidt-Phillips (SP) considera un componente determinístico polinómico. Nosotros, dependiendo de cada serie, elegimos el componente determinístico más apropiado para favorecer la estacionariedad de la serie. Por otro lado, la prueba de Zivot-Andrews (ZA) considera hipótesis alternativas de quiebre estructural, ya sea en media (nivel) como en pendiente.

La evidencia no es muy concluyente al respecto de la presencia de una raíz unitaria, salvo para el caso de la medida de riesgo de crédito para préstamos a empresas medianas, que en todos los tipos de pruebas no rechaza la hipótesis nula, es decir, que ninguna de las seis pruebas puede rechazar un comportamiento de marcha aleatoria (raíz unitaria). Para el resto de casos, la evidencia es mixta. Por ejemplo, el riesgo de crédito para préstamos hipotecarios rechaza el comportamiento no estacionario cuando se permite una tendencia cuadrática o un quiebre en pendiente de una tendencia lineal.

Cuadro 1: Resultado de Pruebas de Raíz Unitaria para  $\ln\left(\frac{RC}{1-RC}\right) - H_0$  : Raíz Unitaria

	ADF	PP	DF-GLS	ERS	SP	ZA
<i>Riesgo de Crédito para préstamos personales</i>						
Revolvente	Rechaza	No Rechaza	No Rechaza	No Rechaza	Rechaza	Rechaza
Línea mayor a 3K soles	Rechaza	No Rechaza	No Rechaza	Rechaza	Rechaza	Rechaza
Línea menor a 3K soles	No Rechaza	No Rechaza	No Rechaza	No Rechaza	Rechaza	Rechaza
Sin línea	No Rechaza					
No Revolvente	Rechaza	No Rechaza	Rechaza	No Rechaza	Rechaza	Rechaza
Sin convenio	No Rechaza	No Rechaza	Rechaza	No Rechaza	Rechaza	Rechaza
Con convenio	No Rechaza					
Hipotecario	No Rechaza	No Rechaza	No Rechaza	No Rechaza	Rechaza	Rechaza
<i>Riesgo de Crédito para préstamos a empresas</i>						
Mayoristas	Rechaza	Rechaza	No Rechaza	No Rechaza	Rechaza	No Rechaza
Medianas	No Rechaza					
PYMES	Rechaza	No Rechaza	Rechaza	No Rechaza	Rechaza	Rechaza
Pequeñas con Bancos	No Rechaza	No Rechaza	Rechaza	Rechaza	Rechaza	No Rechaza
Pequeñas con no Bancos	Rechaza	No Rechaza	Rechaza	Rechaza	No Rechaza	Rechaza

ADF: Dickey-Fuller aumentado; PP: Phillips-Perron; DFGLS: Dickey-Fuller con GLS detrending; ERS: Elliot-Rothemberg-Stock Point Optimal; SP: Schmidt-Phillips; ZA: Zivot-Andrews.

Estos resultados nos llevan a utilizar las primeras diferencias de las medidas de riesgo de crédito en el caso de modelos con parámetros invariantes en el tiempo. En el caso de modelos con parámetros cambiantes en el tiempo, emplearemos las medidas de riesgo de crédito sin diferenciar.

Por otro lado, también hemos realizado pruebas de cointegración entre diversas medidas de riesgo de crédito. Se analizaron tres grupos de medidas de riesgo de crédito para préstamos personales: el primero agrupa las medidas agregadas de segmentos de préstamos personales, como la medida de riesgo para créditos revolvente, no revolvente e hipotecario. El segundo, las medidas del segmento de créditos revolvente por tamaño de línea. Mientras que el tercer grupo analizado incluye las medidas de riesgo para préstamos no revolvente con y sin convenio. En el caso de préstamos a empresas, se han considerado dos grupos: las medidas agregadas de riesgo de crédito para préstamos a empresas mayoristas, medianas y pymes; el otro grupo, las medidas de los sub-segmentos de créditos a pequeñas empresas otorgados por bancos y o bancos. La Tabla 2 muestra el resultado de aplicar la prueba de Johansen a los cinco grupos definidos anteriormente. Se observa que el único grupo donde se detecta una relación de largo plazo es entre las medidas de riesgo de crédito agregado para los préstamos personales (revolvente, no revolvente e hipotecario). Para el resto de variables, tomaremos primeras diferencias a fin de utilizar los modelos VAR.

## 4.2. Análisis de Causalidad a la Granger

Para determinar las variables a considerar en el modelo VAR realizaremos un análisis de causalidad a la Granger. De esta manera, evitamos incluir un número excesivo de variables, ya que, como se mencionó anteriormente, un mayor número de variables y retardos incrementa el problema de dimensionalidad. Hemos considerado un conjunto de variables macroeconómicas y financieras para cada medida de riesgo (en primeras diferencias) y se ha considerado una cantidad de retardos máxima de 9 para la prueba de causalidad. En la Tabla 3 se puede apreciar el resultado de las pruebas de causalidad a lo Granger con la primera diferencia de cada medida de

Cuadro 2: Resultado de prueba de Cointegración Multivariado de Johansen

Relaciones de cointegración ( $r$ )	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
$r = 0$	Rechaza	No Rechaza	No Rechaza	No Rechaza	No Rechaza
$r = 1$	No Rechaza	–	–	–	–
$r = 2$	–	–	–	–	–

Grupo 1: Revolvente, No revolvente, Hipotecario. Grupo 2: Revolvente, Revolvente con línea mayor a 3K soles, Revolvente con línea menor a 3K soles, Revolvente sin línea. Grupo 3: No Revolvente con convenio, No Revolvente sin convenio. Grupo 4: Mayoristas, Medidas, Pymes. Grupo 5: Pymes, Pequeñas con bancos, Pequeñas con no bancos.

riesgo de crédito. Se observa que salvo el caso de la medida de riesgo para préstamos revolventes sin línea de crédito, que falla la prueba de causalidad para cualquier variable extra del conjunto considerado, el resto de medidas si están relacionadas con algunas variables macroeconómicas y financieras.

Para el caso de préstamos revolventes, está relacionada con seis de las nueve variables macrofinancieras. En el modelo VAR utilizaremos solamente: la variación 12 meses del consumo, del ingreso real promedio, del crédito de consumo y los niveles de desempleo y expectativas económicas. Este conjunto de empresas es el mismo para el sub-segmento de préstamos personales con línea de crédito mayor a 3K soles. En el caso de los préstamos con línea menor a 3K soles, la única variable que supero la prueba de causalidad a lo granger es la variación 12 meses del PIB real. Para los préstamos no revolventes utilizamos la variación 12 meses del consumo, del ingreso real promedio, del crédito de consumo y los niveles de desempleo y el spread de tasas EMBI. Finalmente, para la medida de riesgo de crédito hipotecario emplearemos la variación 12 meses del consumo, del ingreso real promedio, del crédito hipotecario y el nivel de desempleo.

Cuadro 3: Causalidad a-la-Granger para medidas de riesgo de crédito - Préstamos Personales

	$\Delta_{12M}PIB$	$\Delta_{12M}Consumo$	$\Delta_{12M}Ing.Promedio$	$\Delta_{12M}ToT$	$\Delta_{12M}Tipo.Cambio$	$\Delta_{12M}Credito$	$Expect$	$Desempleo$	$EMBI$
Revolvente	Sí causa	Sí causa	Sí causa	No causa	No causa	Sí causa	Sí causa	Sí causa	No causa
Línea mayor a 3K soles	Sí causa	Sí causa	Sí causa	No causa	No causa	Sí causa	Sí causa	Sí causa	No causa
Línea menor a 3K soles	Sí causa	No causa	No causa	No causa	No causa	No causa	No causa	No causa	No causa
Sin línea	No causa	No causa	No causa	No causa	No causa	No causa	No causa	No causa	No causa
No Revolvente	Sí causa	Sí causa	Sí causa	No causa	No causa	Sí causa	No causa	Sí causa	Sí causa
Sin Convenio	Sí causa	Sí causa	Sí causa	No causa	No causa	Sí causa	No causa	Sí causa	Sí causa
Con Convenio	Sí causa	Sí causa	No causa	No causa	No causa	Sí causa	No causa	Sí causa	Sí causa
Hipotecario	Sí causa	Sí causa	Sí causa	No causa	No causa	No causa	No causa	Sí causa	No causa

En la Tabla 4 se tienen el resultado para las medidas de riesgo de crédito para préstamos a empresas. Para los préstamos a empresas mayoristas utilizaremos la variación 12 meses del PIB, del precio de petróleo, del crédito mayorista y las expectativas de demanda y sector y la tasa de desempleo. Para el caso de préstamos a empresas medianas se utilizará la variación interanual del ingreso real promedio, del crédito a empresas medianas y el nivel de desempleo. Para la medida de riesgo para préstamos a pymes utilizaremos la variación interanual del PIB real, el ingreso real promedio, el precio del cobre, el crédito a pymes, y los niveles de expectativas de demanda, la tasa de desempleo y el spread de tasas EMBI. Un conjunto similar será empleado para las medidas de riesgo de préstamos a pequeñas empresas otorgadas por bancos e instituciones no bancarias.

Cuadro 4: Causalidad a-la-Granger para medidas de riesgo de crédito - Préstamos a Empresas

	$\Delta_{12M}PIB$	$\Delta_{12M}Ing.Promedio$	$\Delta_{12M}ToT$	$\Delta_{12M}Tipo.Cambio$	$\Delta_{12M}Copper$	$\Delta_{12M}Oil$	$\Delta_{12M}Credito$	<i>Exp.Econ</i>	<i>Exp.Demand</i>	<i>Exp.Sector</i>	<i>Desempleo</i>	<i>EMBI</i>	<i>Bono10Y</i>
Mayorista	Sí causa	No causa	No causa	No causa	No causa	Sí causa	Sí causa	No causa	Sí causa	Sí causa	Sí causa	No causa	No causa
Medianas	No causa	Sí causa	No causa	No causa	No causa	No causa	Sí causa	No causa	No causa	No causa	Sí causa	No causa	No causa
Pymes	Sí causa	Sí causa	No causa	No causa	Sí causa	Sí causa	Sí causa	No causa	Sí causa	Sí causa	Sí causa	Sí causa	No causa
Peq. con bancos	Sí causa	Sí causa	No causa	No causa	No causa	Sí causa	Sí causa	Sí causa	Sí causa	Sí causa	Sí causa	Sí causa	No causa
Peq. con no bancos	Sí causa	Sí causa	No causa	No causa	No causa	Sí causa	Sí causa	Sí causa	Sí causa	Sí causa	Sí causa	Sí causa	No causa

### 4.3. Resultados de Modelos Univariados

En la Tabla 5 se observa dos medidas de precisión de la predicción a  $h = 1$  y  $h = 6$  períodos adelante utilizando modelos  $ARIMA(p, d, 0)$ . Para todas las medidas de riesgo de crédito cuando el modelo  $ARIMA$  no incluye una tendencia lineal o superior, el modelo elegido es un modelo con un orden de integración igual a 1 ( $d = 1$ ). En dichos casos, para las series de riesgo crediticio para préstamos revolvente y no revolvente, la primera diferencia sigue un modelo  $AR(1)$ . Por el contrario, para el riesgo de crédito de préstamos hipotecarios, el mejor modelo univariado para la primera diferencia es un ruido blanco. Esto quiere decir que la medida de riesgo para créditos hipotecarios es una marcha aleatoria según el modelo univariado.

Cuando se introduce un componente determinístico lineal o superior, el orden de integración es 0 ( $d = 0$ ), es decir, no es necesario diferenciar la serie. Para la serie de riesgo de crédito para préstamos revolventes, el componente autoregresivo es de orden 4 sea el caso de una tendencia lineal, cuadrática o cúbica. En el caso del riesgo de créditos no revolventes, la parte autoregresiva es de orden 3; mientras que para el riesgo de préstamos hipotecarios, el orden autoregresivo es 1 tanto para una tendencia lineal, cuadrática o cúbica.

La precisión para la predicción de la serie de riesgo de créditos revolventes del modelo  $ARIMA$  sin ningún tipo de tendencia (lineal, cuadrática o cúbica) es la mejor en comparación al resto de modelos univariados para ambos horizontes de predicción ( $h = 1, 6$ ). En el caso del riesgo de préstamos no revolventes, la precisión a un período ( $h = 1$ ) del modelo  $ARIMA$  sin tendencia es la mayor de los cuatro modelos, pero para el horizonte de predicción  $h = 6$ , el modelo  $ARIMA$  con tendencia lineal es el que produce las predicciones más precisas en comparación a las otras. Finalmente, en el caso del riesgo de crédito para préstamos hipotecarios, la mayor precisión para ambos horizontes de predicción ( $h = 1, 6$ ) es la obtenida por el modelo  $ARIMA$  sin tendencia (marcha aleatoria).

En el caso de las medidas de riesgo para préstamos a empresas, la Tabla 6 muestra los resultados obtenidos. Al igual que en el caso de préstamos personales, cuando no se incorpora un componente determinístico, el orden de integración de las series es 1, salvo para la medida de riesgo de crédito para pymes que en cualquier caso, el mejor modelo  $ARIMA$  seleccionado es estacionario, es decir, que su orden de integración es 0. Respecto a la precisión en la predicción: en el caso de la medida de riesgo de crédito para préstamos a empresas mayoristas (grandes y corporativos), el modelo que da las predicciones menos imprecisas es el modelo  $ARIMA$  con una tendencia lineal, aunque seguido muy de cerca por el modelo  $AR(1)$  en primeras diferencias. Para la medida de riesgo de créditos a empresas medianas, el modelo univariado que arroja mejores medidas de precisión es el modelo  $AR(1)$  con una tendencia cúbica, seguido bastante de cerca por el modelo que trata la serie de riesgo para préstamos a empresas medianas como una marcha aleatoria. Finalmente, para la medida de riesgo para créditos a PYMEs, el modelo univariado con mejores indicadores de precisión es el  $AR(2)$  con una tendencia lineal.

Cuadro 5: Evaluación de modelos de predicción univariados - Préstamos Personales

Modelo	Horizonte de Predicción			
	$h = 1$		$h = 6$	
	RMSE	MAE	RMSE	MAE
<i>Consumo Revolvente</i>				
ARIMA(1,1,0)	0,147	0,112	0,921	0,874
ARIMA(4,0,0)+Lineal	0,510	0,477	5,765	5,673
ARIMA(4,0,0)+Cuadrático	0,266	0,228	0,954	0,851
ARIMA(4,0,0)+Cúbico	0,556	0,522	6,180	6,077
<i>Consumo No Revolvente</i>				
ARIMA(1,1,0)	0,092	0,076	0,423	0,398
ARIMA(3,0,0)+Lineal	0,094	0,067	0,378	0,311
ARIMA(3,0,0)+Cuadrático	0,116	0,101	0,385	0,359
ARIMA(3,0,0)+Cúbico	0,250	0,241	1,679	1,652
<i>Hipotecario</i>				
ARIMA(0,1,0)	0,027	0,022	0,042	0,033
ARIMA(1,0,0)+Lineal	0,035	0,029	0,129	0,125
ARIMA(1,0,0)+Cuadrático	0,156	0,152	0,143	0,139
ARIMA(1,0,0)+Cúbico	0,029	0,023	0,056	0,051

Cuadro 6: Evaluación de modelos de predicción univariados - Préstamos a Empresas

Modelo	Horizonte de Predicción			
	$h = 1$		$h = 6$	
	RMSE	MAE	RMSE	MAE
<i>Mayorista</i>				
ARIMA(1,1,0)	0,179	0,130	0,368	0,331
ARIMA(1,0,0)+Lineal	0,177	0,125	0,255	0,229
ARIMA(1,0,0)+Cuadrático	0,219	0,167	0,431	0,392
ARIMA(1,0,0)+Cúbico	0,224	0,175	0,623	0,455
<i>Medianas</i>				
ARIMA(0,1,0)	0,346	0,229	0,966	0,793
ARIMA(1,0,0)+Lineal	0,347	0,237	0,979	0,894
ARIMA(1,0,0)+Cuadrático	0,484	0,385	1,720	1,704
ARIMA(1,0,0)+Cúbico	0,350	0,233	0,872	0,791
<i>Pymes</i>				
ARIMA(2,0,0)	0,242	0,191	0,892	0,796
ARIMA(2,0,0)+Lineal	0,239	0,189	0,665	0,561
ARIMA(2,0,0)+Cuadrático	2,275	2,176	2,145	2,044
ARIMA(2,0,0)+Cúbico	0,341	0,284	2,466	2,429

#### 4.4. Resultados de Modelos VAR

Respecto a los resultados utilizando modelos multivariados, la Tabla 7 muestra las medidas de precisión de los modelos VAR considerados para las medidas de riesgo para préstamos personales. Para la medida de riesgo para créditos revolventes, para la predicción a 1 período los dos mejores modelos son un VAR cointegrado con una tendencia y un VAR en diferencias; sin embargo, para la predicción a seis periodos adelante, los modelos con mejores medidas de precisión son el VAR cointegrado con tendencia y el VAR con parámetros cambiantes en el tiempo, en tanto que el VAR en diferencias genera errores promedios de más de un punto porcentual.

Para la medida de riesgo de crédito para préstamos no revolvente los mejores modelos de predicción a 1 y 6 períodos adelante son los modelos VAR cointegrado con un intercepto como componente determinístico y un VAR en diferencias con regularización (LASSO). En términos de precisión, estos dos modelos están seguidos bastante de cerca por la predicción generada por un VAR con parámetros cambiantes en el tiempo. En el caso de la medida de riesgo para créditos hipotecarios, todos los modelos multivariados performan bastante bien para predicciones de 1 período en adelante. Mientras, para una predicción de horizonte  $h = 6$ , los dos mejores modelos son un VAR en diferencias regularizado y un VAR en niveles con parámetros cambiantes en el tiempo.

Cuando combinamos las predicciones generadas por todos los modelos (salvo el VAR con parámetros cambiantes en el tiempo) podemos mejorar significativamente las medidas de predicción. Para el caso de la medida de riesgo de créditos revolventes, la combinación utilizando pesos de una regresión incrementa la precisión en casi el doble, en promedio. Para el caso del riesgo de préstamos revolventes, la combinación de predicciones incrementa la precisión en algo más del doble. Mientras que para la medida de riesgo para créditos hipotecarios, la ganancia de precisión de la combinación de predicciones es similar (casi el doble) que en los casos anterior. Cuando se hace la combinación utilizando para el horizonte de predicción de 6 períodos hacia adelante, las mejoras en precisión son bastante evidentes para todas las medidas de riesgo. Sin embargo, esto puede resultar un poco engañoso, ya que la cantidad de datos es muy reducida para el caso de predicciones a 6 períodos. Por tanto, hay que tomar con cuidado este incremento en la precisión ya que nuestros pesos podrían estar sobre ajustando.

Cuadro 7: Evaluación de modelos de predicción VAR - Préstamos Personales

Modelo	Horizonte de Predicción			
	$h = 1$		$h = 6$	
	RMSE	MAE	RMSE	MAE
<i>Consumo Revolvente</i>				
<i>VAR Cointegrado</i>				
Intercepto	0,207	0,174	0,416	0,338
Tendencia	0,204	0,172	0,368	0,299
<i>VAR en diferencias</i>				
VAR	0,205	0,171	1,270	1,237
Lasso VAR	0,241	0,208	1,492	1,427
<i>VAR Bayesiano en niveles</i>				
VAR	0,215	0,157	0,673	0,572
<i>Consumo No Revolvente</i>				
<i>VAR Cointegrado</i>				
Intercepto	0,086	0,072	0,268	0,221
Tendencia	0,204	0,181	0,512	0,481
<i>Multivariados en diferencias</i>				
VAR	0,186	0,143	0,908	0,640
Lasso VAR	0,097	0,077	0,377	0,355
<i>VAR Bayesiano en niveles</i>				
VAR Bayesiano	0,118	0,103	0,478	0,450
<i>Hipotecario</i>				
<i>VAR Cointegrado</i>				
Intercepto	0,026	0,021	0,056	0,049
Tendencia	0,033	0,028	0,079	0,063
<i>Multivariados en diferencias</i>				
VAR	0,027	0,022	0,075	0,063
Lasso VAR	0,027	0,022	0,039	0,031
<i>BVAR en niveles</i>				
VAR Bayesiano	0,029	0,023	0,054	0,046

Para el caso de medidas de riesgo de crédito para empresas, el mejor modelo multivariado de predicción para 1 y 6 períodos hacia adelante es el VAR simple en primeras diferencias. En el caso del riesgo de crédito para préstamos a empresas medianas la mejor predicción para ambos horizontes de predicción es la generada por un VAR en diferencias con regularización, es decir, estimado con LASSO. Un resultado similar se observa para el caso del riesgo de crédito para préstamos a PYMEs.

La combinación utilizando pesos de una regresión incrementa la precisión de la predicción del

Cuadro 8: Combinación de predicciones - Préstamos Personales

Variable	Horizonte de Predicción			
	$h = 1$		$h = 6$	
	RMSE	MAE	RMSE	MAE
Revolvente	0,081	0,066	0,048	0,041
No Revolvente	0,040	0,031	0,024	0,019
Hipotecario	0,010	0,008	0,011	0,009

Cuadro 9: Evaluación de modelos de predicción VAR - Préstamos a Empresas

Modelo	Horizonte de Predicción			
	$h = 1$		$h = 6$	
	RMSE	MAE	RMSE	MAE
<i>Mayorista</i>				
<i>VAR en diferencias</i>				
VAR	0,178	0,129	0,378	0,322
Lasso VAR	0,196	0,144	0,385	0,350
<i>VAR Bayesiano en niveles</i>				
VAR	0,187	0,129	0,381	0,343
<i>Medianas</i>				
<i>Multivariados en diferencias</i>				
VAR	0,383	0,271	1,379	1,304
Lasso VAR	0,345	0,226	0,849	0,692
<i>VAR Bayesiano en niveles</i>				
VAR Bayesiano	0,389	0,278	1,460	1,304
<i>PYMEs</i>				
<i>Multivariados en diferencias</i>				
VAR	0,373	0,302	1,911	1,593
Lasso VAR	0,301	0,236	1,342	1,201
<i>BVAR en niveles</i>				
VAR Bayesiano	0,336	0,270	1,526	1,430

riesgo de crédito para préstamos a empresas mayoristas (grandes y corporativos), aunque no en una gran medida como en el caso de préstamos personales. En particular, la precisión mejora en un 50% para predicciones a 1 período en adelante; sin embargo, para predicciones a 6 períodos adelante, esta ganancia de precisión sí es significativa. Para el caso del riesgo de préstamos a empresas medianas, la ganancia de precisión a 1 período si es bastante mayor, casi el doble; mientras que para la predicción a 6 períodos adelante, la ganancia es notoriamente alta, casi

diez veces más. Una situación similar se aprecia para la medida de riesgo para PYMES. Sin embargo, como en el caso de combinaciones para préstamos personales, debemos de tomar con cuidado el resultado para la predicción a 6 periodos adelante.

Cuadro 10: Combinación de predicciones - Préstamos a Empresas

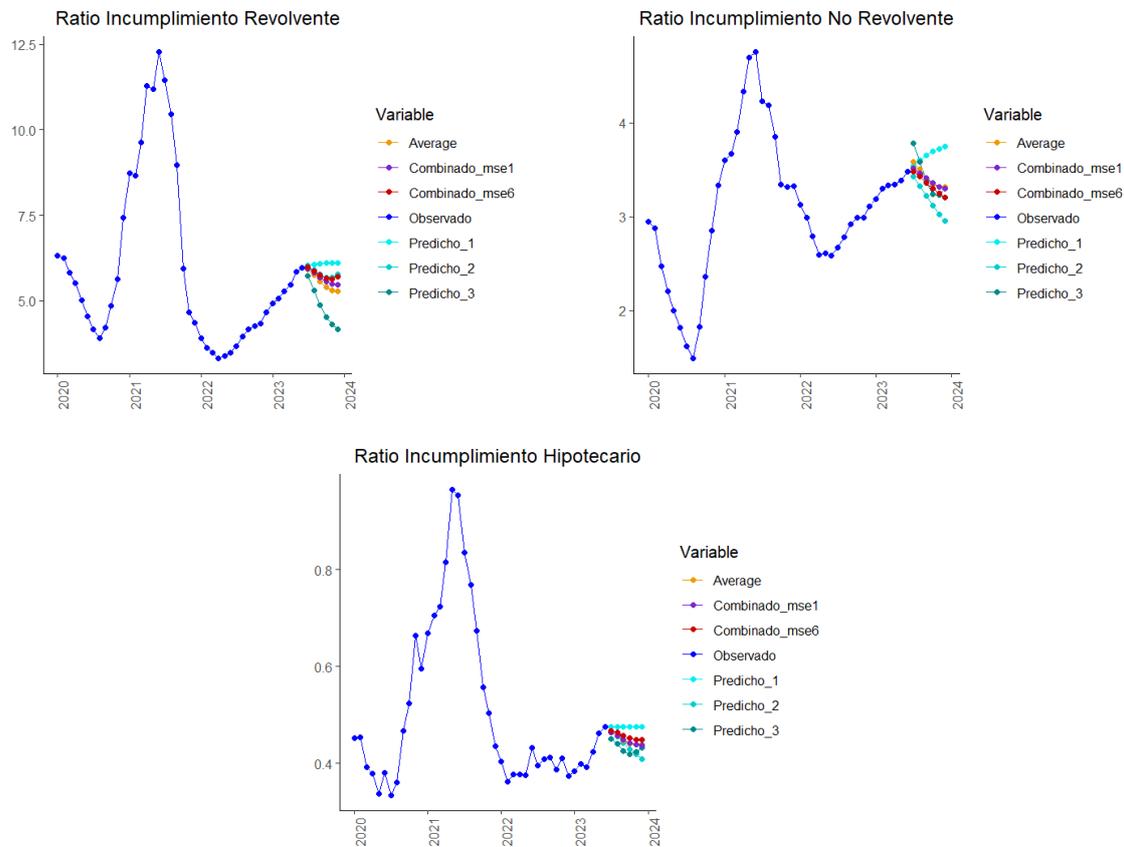
Variable	Horizonte de Predicción			
	$h = 1$		$h = 6$	
	RMSE	MAE	RMSE	MAE
Mayorista	0,119	0,102	0,124	0,116
Medianas	0,221	0,160	0,080	0,073
PYMEs	0,143	0,126	0,088	0,080

## 5. Predicción fuera de muestra

Ahora realizaremos un ejercicio de predecir cuál es la evolución de las medidas de riesgo fuera del rango para la muestra de validación o prueba. Es decir, buscaremos predecir los siguientes 6 meses posteriores a Junio de 2023.

La Figura 5 muestra el resultado empleando modelos con parámetros constantes en el tiempo para la predicción fuera de muestra para los siguientes seis meses posteriores a Junio 2023. No hemos considerado todos los modelos, sino que seleccionamos aquellos con las mejores medidas de precisión, en particular, para un periodo en adelante. Hemos considerado 3 tipos de modelo para las medidas agregadas de riesgo de crédito para préstamos personales (revolvente, no revolvente e hipotecario). Las predicciones para créditos revolventes y no revolventes tienen mucha variabilidad. El mejor modelo univariado predice un incremento en las medidas de riesgo, mientras que las predicciones usando modelos multivariados predicen una caída de las medidas (aunque con algún salto en la predicción a 1 período). En el caso del riesgo de créditos hipotecarios, los modelos con parámetros constantes en el tiempo predicen o un nivel constante para la medida de riesgo (modelo univariado) o una caída de dicha medida con modelos multivariados.

Figura 5: Predicción fuera de muestra a 6 períodos: Modelos con parámetros constantes - Préstamos Personales

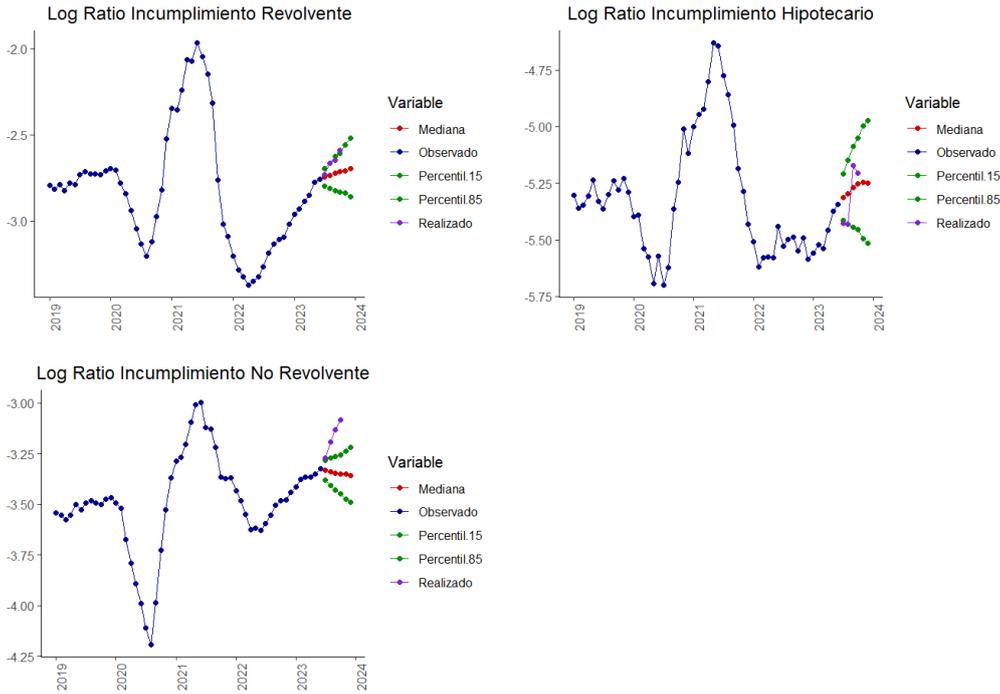


Cuando empleamos las predicciones derivadas de un modelo VAR con parámetros cambiantes en el tiempo, podemos estimar una distribución para la predicción de la media condicional. La mediana de dichas estimaciones para la medida de riesgo de crédito para préstamos revolventes indica, como se puede apreciar en la Figura 6, una subida sostenida de la medida de riesgo de crédito. Asimismo, el conjunto creíble de predicciones, formado por todo el rango entre el percentil 15 y 85 de las predicciones para la media, sugiere que hay una gran parte de la distribución de la predicción que indica que a corto plazo (1 período hacia adelante) la medida de riesgo de crédito de préstamos revolventes se mantiene cerca del nivel de junio 2023, pero que durante los meses siguientes, se evidencia que las predicciones indican una subida de dicho ratio de incumplimiento. Cuando se compara con lo realizado, se puede notar en la gráfica, que efectivamente la medida de riesgo de crédito ha caído en límite superior del conjunto creíble de predicciones.

Para el caso de la medida de riesgo de crédito para préstamos no revolventes, solo el modelo univariado predice una subida sostenida de la medida de riesgo, mientras que el resto de modelos, incluidos las combinaciones, apuntan a un descenso de la medida de riesgo. Por otro lado, la predicción mediana del modelo de con parámetros cambiantes en el tiempo (Figura 6) muestra un descenso muy ligero de la medida de riesgo en los siguientes seis meses. Y dentro de su conjunto creíble, se puede observar que el percentil 85 muestra un ascenso suave en los primeros meses, que luego se acelera. Cuando se compara con lo realizado actualmente, se puede observar que la predicción a un período hacia adelante está muy cerca del percentil 85, sin embargo, luego el valor de la medida de riesgo sube más rápido, saliendo fuera del rango superior del conjunto creíble.

La predicción para el riesgo de crédito de préstamos hipotecarios empleando modelos de parámetros constantes (Figura 5) muestra que mantenimiento del nivel de junio 2023 o un descenso muy suave para los siguientes seis meses. En cambio, la predicción a seis meses del modelo multivariado con parámetros cambiantes nos muestra un crecimiento sostenido, que se desacelera poco a poco para el valor mediano de la predicción. El valor realizado muestra una volatilidad bastante alta, los dos primeros meses se observó un nivel menor al de junio 2023, pero para los siguientes dos meses la medida de riesgo experimentó un salto significativo. Aun así, el valor realizado se encuentra dentro del rango creíble.

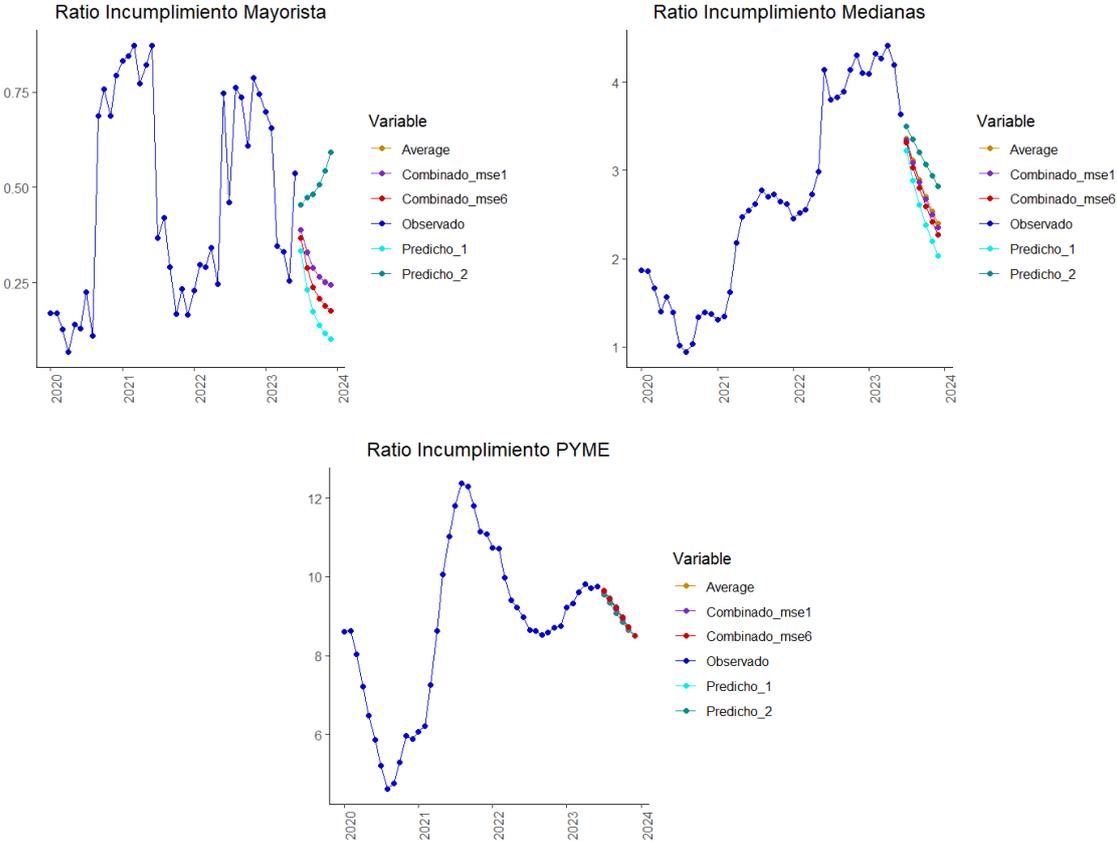
Figura 6: Predicción fuera de muestra a 6 períodos: Modelos con parámetros cambiantes - Préstamos Personales



La Figura 7 muestra el resultado empleando modelos con parámetros constantes en el tiempo para la predicción fuera de muestra para los siguientes seis meses posteriores a Junio 2023 para las medidas de riesgo de crédito a empresas (mayoristas, medianas y PYMEs). Se han considerado solo el mejor modelo univariado y el mejor multivariado para este ejercicio. Las predicciones para créditos mayoristas tienen mucha variabilidad. El mejor modelo univariado predice un descenso rápido de la medida de riesgo, mientras que el modelo multivariado, si bien predice una caída a 1 período, los siguientes períodos muestran un ascenso rápido.

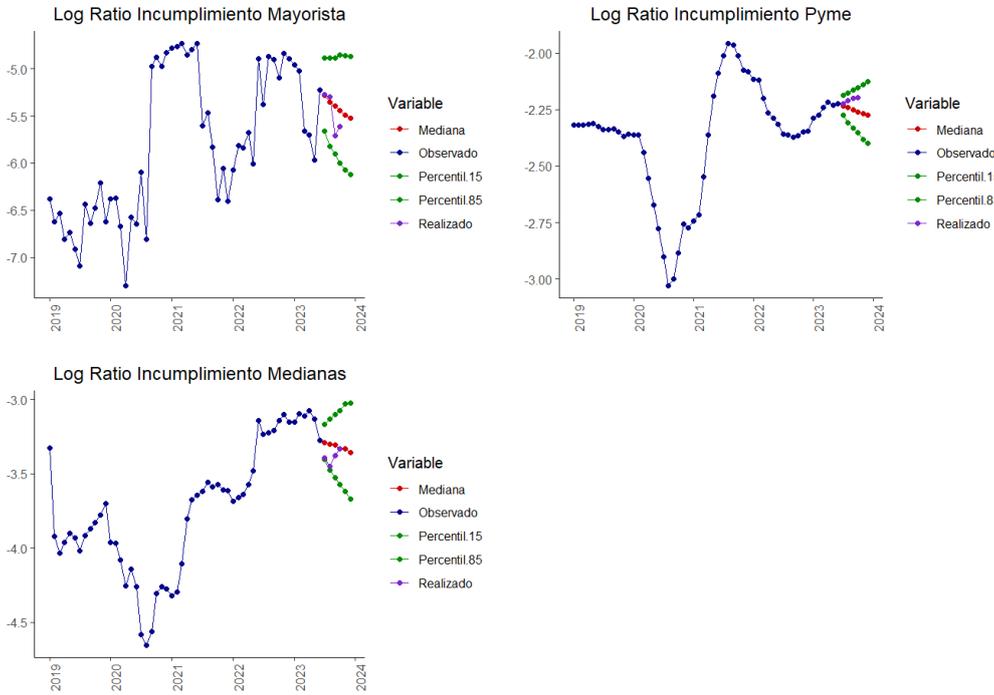
Las predicciones para el riesgo de créditos a medianas y PYMEs, por el contrario, muestra cierta homogeneidad de dirección de los modelos de predicción. Siendo el de la medida de riesgo para préstamos a medianas la que mayor varianza muestra, mientras que la de PYME presenta una variabilidad muy pequeña entre las diferentes predicciones. En cualquier caso, para estas dos medidas de riesgo de crédito se pronostica un descenso en la probabilidad de impago a 12 meses.

Figura 7: Predicción fuera de muestra a 6 períodos: Modelos con parámetros constantes - Préstamos a Empresas



Cuando se emplea un modelo con parámetros cambiantes en el tiempo, estimado con técnicas bayesianas, se tiene un panorama similar. El pronóstico mediano para las tres medidas de riesgo de crédito para los tres segmentos de préstamos a empresas indican un descenso suave de la medida de riesgo, siendo la predicción de la medida de riesgo para corporativos la que mayor rápido desciende, según los pronosticado. Sin embargo, el conjunto creíble de predicciones muestra un amplio rango. En el caso del riesgo de crédito de corporativos, el valor realizado coincide bastante bien con la trayectoria del pronóstico mediano; algo similar se observa en el caso de la medida de riesgo para créditos a PYMEs. Por el contrario, los valores observados para el riesgo de crédito para empresas medianas muestran un aumento sostenido en los primeros cuatro meses posteriores a junio. Esto se encuentra dentro del conjunto creíble de la predicción, y sigue más de cerca la evolución del percentil 85 de la predicción, que muestra una subida a un ritmo similar.

Figura 8: Predicción fuera de muestra a 6 períodos: Modelos con parámetros cambiantes - Préstamos Empresas



## 5.1. Comentarios Finales y Agenda Futura

Nuestro estudio muestra diferentes modelos de predicción para las medidas de riesgo de crédito para distintos segmentos de colocaciones dentro del sistema financiero peruano. Podemos mostrar cómo los modelos multivariados mejoran en ciertos casos la precisión de los modelos univariados, especialmente si tienen regularización. Por otro lado, es importante señalar, que los modelos con parámetros cambiantes en el tiempo muestran un mejor desempeño cuando predicen fuera de muestra que los modelos con parámetros invariantes. Esto es de especial relevancia sobre todo en un contexto de alta incertumbre macroeconómica.

Por otro lado, los modelos que se han desarrollado permiten al investigador proceder a calcular predicciones condicionadas. En este estudio hemos generado dichas predicciones de forma automática. Sin embargo, dichas predicciones sobre la evolución de las diferentes variables macroeconómicas, pueden ser provistas por un experto o por lo que el *policy-maker* considera plausible para dichas variables. Entonces, será posible generar predicciones de las medidas de riesgo sobre la base de dichas sendas futuras. Esto es una gran ventaja en comparación a los modelos de tipo caja negra, como son los de aprendizaje automático.

## Referencias

- Baumeister, C. and Kilian, L. (2015). Forecasting the real price of oil in a changing world: a forecast combination approach. *Journal of Business & Economic Statistics*, 33(3):338–351.
- Bohórquez, D., Matienzo, V. H., and Olivares, A. (2017). The implications of loan maturity on the probability of default: evidence from peruvian long-term loans.
- Budnik, K. B., Balatti, M., Covi, G., Dimitrov, I., Groß, J., Hansen, I., Kleemann, M., Reichenbachas, T., Sanna, F., Sarychev, A., et al. (2019). Macroprudential stress test of the euro area banking system.
- Budnik, K. B., Balatti, M., Dimitrov, I., Groß, J., Kleemann, M., Reichenbachas, T., Sanna, F., Sarychev, A., Sigenko, N., and Volk, M. (2020). Banking euro area stress test model.
- Dendramis, Y., Tzavalis, E., Varthalitis, P., and Athanasiou, E. (2020). Predicting default risk under asymmetric binary link functions. *International Journal of Forecasting*, 36(3):1039–1056.
- Fiordelisi, F., Monferrà, S., and Sampagnaro, G. (2014). Relationship lending and credit quality. *Journal of Financial Services Research*, 46:295–315.
- Foglia, A., Laviola, S., and Reedtz, P. M. (1998). Multiple banking relationships and the fragility of corporate borrowers. *Journal of Banking & Finance*, 22(10-11):1441–1456.
- Hoggarth, G., Sorensen, S., and Zicchino, L. (2005). Stress tests of uk banks using a var approach.
- Hsiao, C. and Wan, S. K. (2014). Is there an optimal forecast combination? *Journal of Econometrics*, 178:294–309.
- Jimenez, G., Salas, V., and Saurina, J. (2006). Determinants of collateral. *Journal of financial economics*, 81(2):255–281.
- Jiménez, G. and Saurina, J. (2004). Collateral, type of lender and relationship banking as determinants of credit risk. *Journal of banking & Finance*, 28(9):2191–2212.
- Kaposty, F., Kriebel, J., and Löderbusch, M. (2020). Predicting loss given default in leasing: A closer look at models and variable selection. *International Journal of Forecasting*, 36(2):248–266.