

Explicabilidad en Modelos de Predicción de la Probabilidad de Default en Cumplimiento del Estándar Internacional NIIF 9

Catalina LOZANO

Departamento de Tecnologías y Sistemas de la Información
Universidad Castilla La Mancha, 13071 Ciudad Real, España

Francisco P. ROMERO

Departamento de Tecnologías y Sistemas de la Información
Universidad Castilla La Mancha, 13071 Ciudad Real, España

RESUMEN

Este artículo presenta un análisis no exhaustivo de alternativas de predicción de Probabilidad de Incumplimiento (PD), pero su principal objetivo es el de probar un conjunto de técnicas multivariadas que buscan facilitar el entendimiento de diferentes modelos de Machine Learning para la estimación de las PD, en línea con lo requerido por la NIIF 9 para modelos de Pérdidas Esperadas, aplicado a la cartera de deuda Residencial de los Estados Unidos.

Se muestran los modelos con los mejores resultados y el proceso que se llevó cabo para el uso de los diferentes métodos, se comentan las pruebas realizadas y se identifican los modelos aptos para la predicción de las PD, así como su análisis de explicabilidad que buscan facilitar su entendimiento y en cierto nivel su revisión. Los ejercicios ejecutados arrojan a los modelos de Redes Neuronales Artificiales como los mejores candidatos en la fase de pruebas.

Palabras Claves: Probabilidad de incumplimiento, Redes Neuronales Artificiales, vectores autoregresivos, estimación, explicabilidad.

1. INTRODUCCIÓN

La Norma Internacional de Información Financiera (NIIF) 9 [1] es el estándar para el reporte, medición, deterioro y reconocimiento de los de Instrumentos Financieros, diseñada por el International Accounting Standard Board (IASB) para facilitar y homogenizar la estructura de reportes financieros. Este estándar propone la “Metodología de Deterioro de Valor” para instrumentos financieros, la cual incorpora la medición de riesgo de crédito de las distintas contrapartes dentro de la valoración y reconocimiento de los instrumentos que no se evalúan a valor razonable. El modelo de Pérdidas Esperadas es el descrito por la NIIF 9 el cual contiene dos enfoques de acuerdo a las condiciones de los activos: el enfoque simplificado, diseñado para entidades no financieras con cartera de corto plazo (hasta un año), donde se deberá estimar las pérdidas para toda la vida del instrumento y el enfoque general que contempla estadios de riesgo de acuerdo con la morosidad y la información disponible de la contraparte; ambos incluyen la probabilidad de default, el valor del dinero en el tiempo y las condiciones económicas actuales y esperadas a futuro.

Los requerimientos generados por la normativa han hecho que todas las compañías que reportan sus estados financieros bajo el estándar NIIF tengan que enfrentarse al reto de generar modelos de pérdidas esperadas con determinados parámetros de acuerdo

a las carteras vigentes y la información que disponen, aunque no cuenten con perfiles especializados en elaboración de modelos. Por su parte los supervisores y auditores deben generar estrategias de revisión y auditoría del proceso de determinación de los modelos, su adecuación, fiabilidad y pertinencia.

Atendiendo al contexto presentado, el objetivo primordial de este documento es el de la estimación de la Probabilidad de Incumplimiento (PD) bajo los requerimientos de consideración de riesgo económico prospectivo, teniendo en cuenta la información razonable y sustentable que está disponible sin costo o esfuerzo desproporcionado en la fecha de presentación sobre sucesos pasados, condiciones actuales y pronósticos de condiciones económicas futuras [1].

Múltiples modelos se han venido desarrollando y probando para atender al reto de estimación de PD y de Pérdidas esperadas agregadas, encontrando publicaciones que reflejan una alta capacidad predictiva y la solución de retos a potenciales relaciones no lineales en los denominados modelos de “caja negra”, los cuales en la práctica no suelen tener acogida debido a las limitaciones en su revisión y pertinencia por parte de entes supervisores como pueden ser los reguladores locales o auditores financieros.

Para afrontar parte del reto propuesto en la normativa, relacionado con la necesidad de desarrollar modelos confiables y auditables, se busca emplear técnicas de explicabilidad para poder hacer uso extendido de diferentes tipos de modelos para la predicción de PD mediante modelos multivariados de diferente naturaleza, así como considerar su selección y posibilidades de comparación y entendimiento. Hemos desarrollado modelos de predicción de PD de diferente tipo y aplicado técnicas de explicabilidad a los principales modelos obtenidas, ya que estas técnicas permiten establecer el tipo de relaciones que identifican los modelos, en caso tal de querer realizar recálculos o revisión de consistencias de resultados, aunque no se obtengan los mismos parámetros, si será posible evaluar las relaciones generadas, entender su pertinencia y comparar con otras posibles alternativas de modelamiento, tal como lo hemos realizado, facilitando así el uso de modelos que hoy las compañías no emplean por limitaciones de revisión.

El resto del artículo está organizado como sigue: En la sección 2 se aborda una semblanza de los trabajos más recientes sobre la resolución del problema planteado. En la Sección 3 se explica el trabajo desarrollado desde el proceso de selección de variables y aplicación de los modelos, en la sección 4 se describen los resultados y finalmente en la sección 5 se detallarán las conclusiones y trabajos futuros, derivados de los análisis presentados en este artículo.

2. ANTECEDENTES

Por lo general, las empresas utilizan modelos tradicionales de Mínimos cuadrados ordinarios que pretenden mediante coeficientes que simplifican relaciones, determinar la Probabilidad esperada de incumplimiento. Sin embargo, este tipo de estimaciones asume igual distancia entre categorías de riesgo y relaciones lineales entre la PD [2] y las variables independientes, además de partir de supuesto rígidos que muchas veces no es posible garantizar su cumplimiento, dados comportamientos atípicos en varias etapas de los ciclos económicos. Como alternativa de estimación, es común encontrar el uso de modelos autoregresivos como son: AR, MA, ARIMA, etc, para los cuales se suelen relajar algunas hipótesis o dar por hecho características estadísticas de las variables con el fin de facilitar su uso.

Compañías con equipos especializados tratan de emplear otro tipo de técnicas, un poco más complejas, como pueden llegar a ser los datos de panel [3], técnica que permite mayor variabilidad en la muestra con mejores resultados en las estimaciones que los modelos cross-section y las series temporales [4], aunque requieren grandes volúmenes de información. Otra técnica común está basada en la propuesta de Merton [5] que permite generar un estimador de riesgo adelantado y con una alta correlación con indicadores tradicionales de riesgo de la banca (especialmente en la banca empresarial). Aunque estima probabilidades de quiebra excesivamente altas al contrastar con pruebas back; también resaltan los modelos probit [6] que arrojan mejores resultados en las pruebas de contraste realizadas por los diferentes autores.

Si buscamos técnicas de Machine Learning aplicados a riesgos [7], no necesariamente aplicadas al problema planteada, se encuentran Modelos de Optimización de Portafolio con procesos de decisión de Markov (MDP) [8]; regresión de procesos Gausianos [9] para la determinación de tasas de interés; otros modelos de regresión aplicados a retos financieros [10] [11] [12], modelamiento de series temporales con técnicas GARCH [13], PARCH y EGARCH; además del uso de los modelos ya comentados al inicio de esta sección y algunas técnicas más novedosas pero de aplicación menos común, como son las Redes Neuronales Artificiales (RNA), para clasificación y predicción, así como los modelos Modelos Autorregresivos No Lineales (NAR) y su consideración de variables exógenas.

La ciencia de datos ha evolucionado rápidamente conforme ha avanzado la capacidad computacional y así la complejidad de los modelos y la dificultad para entender la relación de variables, es por eso que en las últimas dos décadas han aumentado los análisis y aplicaciones de técnicas de explicabilidad como un paso final al desarrollo de modelos de Machine Learning e Inteligencia artificial. Es importante destacar que existe una limitación en la aplicación práctica de modelos complejos o de difícil interpretación y auditabilidad, asociada a la estricta regulación que rige el sector financiero. Al ser un negocio de riesgo sistémico y vital importancia para la economía global, se hace necesaria la transparencia en todos los procesos y modelos empleados, es por ello que para el uso de técnicas más complejas se hace necesario ahondar en el entendimiento de las relaciones identificadas y en posibles alternativas de evaluación de los procesos, diferentes a re estimaciones independientes.

Dentro de la ciencia de datos se han venido desarrollando un conjunto de técnicas que destacan por la aplicación de análisis

gráficos como Local Interpretable Model Agnostic Explanations (LIME) [14], X-Shap (Modelo agnóstico aditivo de contribución multiplicativa de las variables) [15], [16] o Partial Dependence Plots (PDPs) [17] que permiten ilustrar relaciones entre las variables y el objetivo de predicción o clasificación.

Un reto para la ciencia de datos ha sido el otorgado por los árboles de decisión y random forest, una de las alternativas propuestas se basa en una serie de análisis que parte de la explicación de relaciones basada en teoría de juegos, efectos de interacción entre características y el entendimiento de la estructura del modelo global basado en la combinación de muchas explicaciones locales de cada predicción [18]. Como alternativa para abordar la explicabilidad y aprovechar sus resultados, se ha propuesto la generación de definiciones de taxonomía de conceptos, cuentas o variables para facilidad de entendimiento [19]. Otra técnica empleada en entendimiento de métodos de clasificación es la de la determinación de ratios de sensibilidad a la predicción frente a los cambios en las entradas y un enfoque que descompone significativamente la decisión en términos de las variables de entrada [20].

Otro método empleado es el desarrollo de modelos que ya contengan características que faciliten la interpretabilidad como la red GAMI, basada en modelos aditivos generalizados con interacciones estructuradas, que busca precisión en la predicción y el entendimiento de las relaciones que establece el modelo.

Por otro lado, una interesante aproximación para el entendimiento de procesos de clasificación se ha desarrollado mediante el análisis de cópulas, donde es posible construir de manera intuitiva mediante las propiedades estadísticas de las variables, sus relaciones [21].

3. DATOS Y MODELOS

Para la elaboración del análisis a presentar se hizo uso de información pública y disponible gratuitamente, publicada por el Banco Mundial en el sitio web Data World Bank, donde se contaba con tasas de morosidad trimestral para diferentes tipos de cartera, así como con información de variables macroeconómicas con la misma periodicidad de actualización. Se realizó un análisis de correlaciones de diversas variables macroeconómicas, que arrojó un set de 8 variables (ver Tabla 1) con un bajo índice correlación entre sí y un nivel alto con las variables excluidas. Una vez realizado el proceso de selección de variables independientes y elegida la tasa de morosidad de la cartera hipotecaria de consumo como variable a modelar, se tomó como referencia una venta de tiempo desde 1991-1 hasta 2018 – 1, según el modelo a emplear se generó una segmentación independiente para modelamiento y pruebas.

Para abordar este problema y considerando las características de la variable a modelar, así como las limitaciones de información, se planteó el uso de tres modelos multivariados para predicción de series temporales:

Tabla 1 Variables independientes seleccionadas

Código de la variable	Descripción
DDURRA3Q086SBEA	Gastos a precios reales por consumo personal.
W207RC1Q156SBEA	Ahorro neto como porcentaje del ingreso nacional bruto.
W986RC1Q027SBEA	Ahorro privado neto, en miles de millones.
A191RL1Q225SBEA	Variación trimestral del producto interno bruto real.
DPCERL1Q225SBEA	Variación porcentual trimestral del gasto de consumo personal real.
DPCERO1Q156NBEA	Variación porcentual acumulada anual del gasto de Consumo personal real.
BPCERO1Q156NBEA	Variación porcentual acumulada anual del gasto de Consumo personal real, sin alimentos y energía.
A191RI1Q225SBEA	Variación trimestral del Producto interno bruto.

Vectores Autoregresivos (VAR): Modelo de ecuaciones simultáneas, que al no tener restricciones puede reconocer las relaciones de las variables en el tiempo (rezagos) [22]. Se definen a partir de la expresión presentada en la Ecuación 1, estos modelos suelen desarrollarse para evaluar relaciones entre diferentes ventanas temporales y buscan el efecto del tiempo en la estimación.

$$X_t = \beta_1 X_{t-1} + \beta_2 X_{t-2} + \dots + \beta_k X_{t-k} + Bz_t + u_t$$

Ecuación 1 VAR (k)

Donde:

X_t : Vector columna que contiene las m variables endógenas seleccionadas

X_{t-i} : Vector columna con las variables endógenas anteriores rezagadas, para $i = 1, 2, \dots, k$

K : Indica el orden máximo de rezagos del modelo

β_i, B : Matrices de coeficientes de regresión a estimar, para $i = 1, 2, \dots, K$

Z_t : Factor de corrección, puede representar constante o tendencia

u_t : Vector de innovaciones, sobre las cuales se deben cumplir los siguientes supuestos:

- No tiene correlación serial (autocorrelación)
- $E(u_t) = 0$
- Matriz de varianza covarianza semidefinida positiva invariante en el tiempo tal que $E(u_t u_t^T) = \Sigma$ (ruido blanco)
- Normalidad multivariada.

Para su aplicación se asumió estacionalidad en las TD, no se hizo uso de pruebas de estacionariedad de las variables exógenas debido al efecto que tienen los cambios estructurales de política económica [23], y se evaluó el Test de Jarque-Bera [24] para validar que los procesos estocásticos analizados son Gaussianos. Para su aplicación se consideró una ventana temporal de 1991 a 2016 de periodicidad trimestral y el set de prueba 2017.

Redes Neuronales Artificiales (RNA): “Una Red neuronal es un modelo computacional, paralelo, compuesto de unidades procesadoras adaptativas con una alta interconexión en ellas” [25]. Estos modelos computacionales parten de unidades de procesamiento (neuronas) que emiten señales las cuales son procesadas mediante conexiones (sinapsis) con capas ocultas

que transforman las señales generando salidas bien sea de predicción o clasificación, estos modelos pueden tener diferentes tipos de entrenamiento, número de neuronas, capas y ajuste. Es por ello que se entenderá como un sistema inteligente de aprendizaje adaptativo, basado en el comportamiento de las neuronas biológicas. Su alcance para solucionar problemas lineales y no lineales a partir del aprendizaje, orientado por información, ofrece una gran flexibilidad a la hora de su implementación.




Ilustración 1. Estructura estructura RNA multicapa

Para el análisis desarrollado, se usaron redes de tipo perceptrón multicapa, de una sola capa, definiendo un muestreo aleatorio en cada entrenamiento del 81% con la totalidad de información disponible (1991 I - 2018 I) y un set de pruebas del 19%. Para su selección se evaluó el error cuadrático medio (mse) del set de pruebas y el estadístico R^2 en la predicción de ambos sets.

Modelos Autorregresivos No Lineales Con Componente Exógeno (NARX):

Son un tipo especial de RNA de tipo perceptrón multicapa usada para el pronóstico de series de tiempo autorregresivas con variables exógenas de relación no lineal, requiere de la definición de capas ocultas, número de neuronas, rezagos y función de entrenamiento, su modelamiento es un proceso de iteración sobre la calibración de los parámetros. Como se ve en la Ilustración 2.




Ilustración 2. Estructura NARX (9,10,1)

Se probaron los supuestos de los residuales los cuales deben distribuirse como ruido blanco y se consideraron el error cuadrático medio (mse) y el estadístico R^2 entre el pronóstico y la observación para la selección del mejor modelo. Al igual que las RNA, se propuso un muestreo aleatorio para la selección de un ser de entrenamiento (81%) y un de pruebas (19%).

El objetivo es vincular a la predicción de la Tasa de incumplimiento variables macroeconómicas y una potencial relación autoregresiva o de efectos estacionarios de las variables macroeconómicas sobre el incumplimiento, para en un posterior análisis, en el caso de los modelos de Redes Neuronales, se realizó un análisis de explicabilidad para facilitar el seguimiento de las relaciones establecidas en los modelos seleccionados.

4. RESULTADOS

En la Tabla 2, se presentan los mejores resultados de los principales modelos probados bajo diferentes técnicas seleccionadas. Cabe destacar que, aunque en la etapa de entrenamiento, o estimación del modelo los test favorecen los modelos tipo VAR, en las fases de pruebas la balanza se inclina hacia los modelos de Redes Neuronales multivariadas NARX y RNA.

Tabla 2 Modelos Probados

N. Mod	Técnica	Horizonte de tiempo modelo	Horizonte de tiempo predicción
1	VAR (1)	1991 I-2016 IV	2017 I-IV
2	VAR (3)	2006 I-2016 IV	2017 I-IV
3	NARX (1, 2-5)	81% Entrenamiento (1991 I - 2018 I)	19% Pruebas (1991 I - 2018 I)
4	NARX (1,4,10)	81% Entrenamiento (1991 I - 2018 I)	19% Pruebas (1991 I - 2018 I)
5	RNA (1,5)	81% Entrenamiento (1991 I - 2018 I)	19% Pruebas (1991 I - 2018 I)
6	RNA (1, 10)	81% Entrenamiento (1991 I - 2018 I)	19% Pruebas (1991 I - 2018 I)

De estos modelos se revisaron tanto el cumplimiento de las hipótesis estadísticas como las pruebas de bondad de ajuste para los conjuntos de entrenamiento y pruebas, teniendo como candidatos los modelos presentados en la Tabla 3, esta permite evidenciar que el mejor modelo para la TD de la cartera Residencial es el ejecutado como RNA de una capa y 10 neuronas.

Tabla 3 Modelos Con Los Mejores Resultados Indicador En Pruebas

No Modelo	R ²	Error Estándar
3	-0.043	0.0135
4	0.983	0.9853
6	0.970	0.0812

En los resultados del modelo 3, se puede identificar mediante el peso de los coeficientes, ver Ilustración 3 de las variables empleadas aquellas con mayor influencia, las cuales fueron: TD-2 (-0.64), Ahorro neto como porcentaje del ingreso nacional bruto-1(-0.29) y misma variable a 3 rezagos (-0.129).

Estimation results for equation TD_SA_Residencial:

```
TD_SA_Residencial = DDURRA3Q086SBEA.11 + w207RC1Q156SBEA.11 + w986RC1Q027SBEA.11 + A191RL1Q225SBEA.11 + A191RI1Q225SBEA.11 + w986RC1Q027SBEA.12 + A1915SBEA.12 + TD_SA_Residencial.12 + w207RC1Q156SBEA.13 + A191RL1Q225SBEA.13 + A191RI1Q225SBEA.13 + const
```

	Estimate	Std. Error	t value	Pr(> t)	***
DDURRA3Q086SBEA.11	-0.0577477	0.0062329	-9.265	3.62e-10	***
w207RC1Q156SBEA.11	-0.2861191	0.0425476	-6.725	2.23e-07	***
w986RC1Q027SBEA.11	0.0015975	0.0002325	6.872	1.51e-07	***
A191RL1Q225SBEA.11	0.0335012	0.0107231	3.124	0.004024	**
A191RI1Q225SBEA.11	-0.0747550	0.0237376	-3.149	0.003777	**
w986RC1Q027SBEA.12	0.0008840	0.0001997	4.426	0.000125	***
A191RL1Q225SBEA.12	0.0306180	0.0122058	2.508	0.017969	*
TD_SA_Residencial.12	-0.6445014	0.1317595	-4.891	3.43e-05	***
w207RC1Q156SBEA.13	-0.1294256	0.0475927	-2.719	0.010929	*
A191RL1Q225SBEA.13	0.0378759	0.0099059	3.824	0.000645	***
A191RI1Q225SBEA.13	-0.0953888	0.0280520	-3.400	0.001978	**
const	6.3884580	0.5987787	10.669	1.49e-11	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Ilustración 3. Resultados estimación Modelo 2 – VAR(3)

Para los modelos destacados en etapa de pruebas, pese a tener algoritmos de estimación, para entender las relaciones establecidas se generaron modelos de árboles de clasificación, sobre entrenados, que buscaban establecer de manera clara las relaciones entre la variable a explicar y las variables independientes. Como se evidencia en los resultados de Los árboles de decisión, presentados en la Ilustración 4 y la Ilustración 5, es posible identificar que ambos modelos preponderan la influencia del ahorro sobre ingresos, al igual que el modelo VAR, además de la variación del consumo real, el gasto como proporción del consumo y en la segmentación final, en el caso del modelo 6, se incluye el ahorro neto como determinante.

En cuanto al establecimiento de las relaciones, la Ilustración 6 y la Ilustración 7 se presentan los gráficos PDP de los modelos de RNA seleccionados, donde la escala presentada refleja amarillo mayor relación a violeta menor relación, nos permite ver que el sentido e intensidad de las relaciones no cambia entre modelos, salvo un leve aumento en la relación presentada en el modelo 6 entre Ahorro sobre ingreso y el Gasto per cápita en consumo.

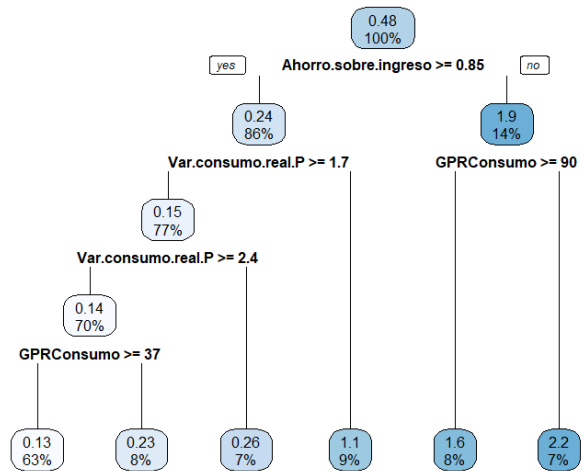


Ilustración 4. Árbol de clasificación Predicción Modelo 4 NARX (1,4,10)

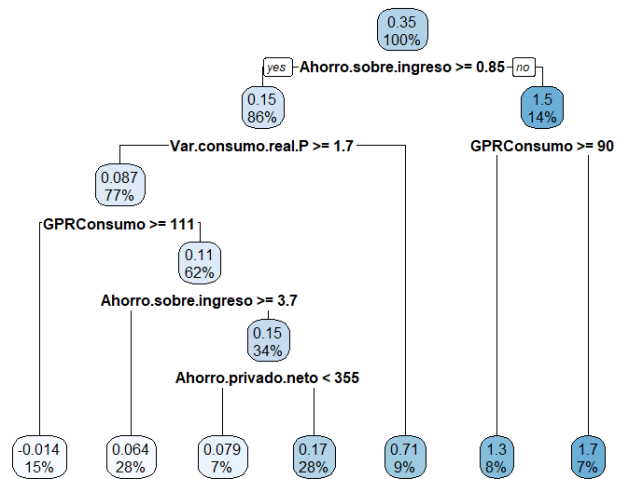


Ilustración 5. Árbol de clasificación Predicción Modelo 6 RNA (1, 10)

5. CONCLUSIONES

Dando cumplimiento a los diferentes objetivos planteados al inicio del presente trabajo, se probaron diversos modelos, donde sobresale la capacidad de predicción en el caso de las Redes Neuronales de diferente naturaleza. Fue posible evidenciar que las variables macroeconómicas seleccionadas arrojaron relaciones similares en los tres modelos destacados resaltando no solo su relevancia para el problema, además de reforzar el objetivo de las NIIF al pedir que se ajuste la provisión acorde con las condiciones económicas históricas y futuras mediante Probabilidades sin sesgo de ciclo o PD *point in time* y otros estándares internacionales como Basilea III [26].

Por otro lado, el uso de modelos de Machine Learning como las Redes Neuronales Artificiales presentan una mejorada capacidad de predicción en etapa de pruebas, por encima de modelos comúnmente empleados y como se pudo evidenciar, arroja relaciones comprobables mediante diversas técnicas de análisis multivariado, además de permitir incorporar modelos que no requieren de una amplia ventana de información o superar estrictas hipótesis estadísticas para su implementación. Adicionalmente y como principal objetivo de este documento, el involucrar en el análisis de resultados diferentes técnicas de explicabilidad no solo permite entender las relaciones establecidas, contrastar las relaciones que establecen las diferentes alternativas propuesta, también facilita el proceso de revisión para la ejecución de estas técnicas mediante simulaciones complementarias, lo que podría proporcionar una alternativa a los procesos de auditoría y revisión de aplicación de estas técnicas en estimación de reportes financieros, que permitiría el uso común de este tipo de técnicas que en la actualidad no se implementan por limitación regulatorias.

Como conclusión general el problema planteado puede abordarse mediante una combinación de técnicas que permitan abordar el pre-procesamiento, modelamiento e interpretación de los modelos diseñados y atender a los requerimientos explícitos de la normativa, además de ampliar los horizontes al tipo de modelos comúnmente empleados.

6. REFERENCIAS

- [1] IFRS Foundation, «IFRS 9,» IFRS, London, 2017.
- [2] A. Perilioglu y S. Tuysuz, «Conditional Sovereign Transition Probability Matrices,» *Procedia Economics and Finance*, vol. 30, pp. 643-655, 2015.
- [3] T. Burdisso y M. Sangiácomo, «Series de tiempo en panel: Una reseña de la evolución metodológica,» *Econostor - ESTUDIOS BCRA*, vol. 68, 2015.
- [4] S. Aguais, L. R. Forest Jr y M. King, «Designing and implementing a Basel II compliant PIT-TTC rating framework,» de *Basel Handbook*, vol. 2, Basel, Basel comite, 2008, pp. 267-297.
- [5] R. Merton, «On the pricing of corporate debt: The risk structure of interest rate,» *Journal of finance*, vol. 29, pp. 449-470, 1974.
- [6] B. Barry, L. R. Forest y S. J. Suchower, «A One-Parameter Representation of Credit Risk and Transition Matrices,» *CreditMetrics Monitor*, pp. 46,56, 1998.




Ilustración 6. PDP Modelo 4 NARX (1,4,10)




Ilustración 7. PDP Modelo 6 RNA (1, 10)

Los resultados reflejan la relevancia de las variables exógenas para la generación de modelos de determinación de PD eficientes, atendiendo por un lado el requerimiento normativo de considerar: “La información utilizada incluirá factores que son específicos para el prestatario, las condiciones económicas generales y una evaluación de la dirección pronosticada y la actual de las condiciones en la fecha de presentación. Una entidad puede utilizar varias fuentes de información, que pueden ser internas (específicas de la entidad) y externas. Las fuentes de información disponibles incluyen la experiencia de pérdidas crediticias históricas, calificaciones internas, experiencia de pérdidas crediticias de otras entidades, y calificaciones, informes y estadísticas externas. Las entidades que no tienen fuentes, o son insuficientes, de información específica de la entidad, pueden utilizar experiencia de grupos similares para el instrumento financiero comparable (o grupo de instrumentos financieros)”. **B5.5.51 -NIIF 9-** [1] y reforzando la pertinencia de su consideración.

- [7] G. Abreu, R. Neves, Horta y Nuno, «Currency exchange prediction using machine learning, genetic algorithms and technical analysis,» 29 05 2018. [En línea]. Available: <https://arxiv.org/abs/1805.11232>. [Último acceso: 29 01 2021].
- [8] E. Krasheninnikova, J. García, R. Maestre, Fernández y Fernando, «Reinforcement learning for pricing strategy optimization in the insurance industry,» *Engineering Applications of Artificial Intelligence*, pp. 8-19, 2019.
- [9] L. Goudenège, A. Molent y A. Zanette, «Gaussian Process Regression for Pricing Variable Annuities with Stochastic Volatility and Interest Rate,» 22 08 2019. [En línea]. Available: <https://arxiv.org/abs/1903.00369>. [Último acceso: 10 02 2021].
- [10] M. Carlehed, «A methodology for point-in-time-through-the-cycle probability of default decomposition in risk classification systems.,» *Jornal of risk model validation*, vol. 6, pp. 3-25, 2012.
- [11] S. Devriendt, K. Antonio, T. Reynkens y R. Verbelen, «Sparse Regression with Multi-type Regularized Feature Modeling,» 10 7 2018. [En línea]. Available: <https://arxiv.org/abs/1810.03136>. [Último acceso: 10 02 2021].
- [12] C. M. Farrelly, S. Namuduri y U. Chukwu, «Quantum Generalized Linear Models,» 01 05 2019. [En línea]. Available: <https://arxiv.org/ftp/arxiv/papers/1905/1905.00365.pdf>. [Último acceso: 10 02 2021].
- [13] X. Cheng, W. Li, P. Yu, X. Zhou y C. Wang, «Modeling threshold conditional heteroscedasticity with regime-dependent skewness and kurtosis,» *Computational Statistics and Data Analysis*, pp. 2590-2604, 2011.
- [14] M. Ribeiro, S. Singh y C. Guestrin, «Local Interpretable Model-Agnostic Explanations (LIME): An Introduction,» O'reilly, 12 Agosto 2016. [En línea]. Available: <https://www.oreilly.com/content/introduction-to-local-interpretable-model-agnostic-explanations-lime/>. [Último acceso: 4 enero 2021].
- [15] L. Bouneder, Y. Léo y A. Lachapelle, «X-SHAP: towards multiplicative explainability of Machine Learning,» 08 06 2020. [En línea]. Available: <https://arxiv.org/abs/2006.04574>. [Último acceso: 11 02 2021].
- [16] V. Belle y I. Papantonis, «Principles and Practice of Explainable Machine Learning,» 18 09 2020. [En línea]. Available: <https://arxiv.org/abs/2009.11698>. [Último acceso: 13 01 2021].
- [17] B. Greewell, «pdp: An R Package for Constructing,» *The R Journal*, vol. 9, pp. 421-436, 2017.
- [18] S. M. Lundberg, G. Erion, H. Chen, A. DeGrave, J. M. Prutkin, B. Nair, R. Katz, J. Himmelfarb, N. Bansal y S.-I. Lee, «Explainable AI for Trees: From Local Explanations to Global Understanding,» 11 05 2019. [En línea]. Available: <https://www.arxiv-vanity.com/papers/1905.04610/>. [Último acceso: 10 02 2021].
- [19] K. Amarasinghe, K. Rodolfa, H. Lamba y R. Ghani, «Explainable Machine Learning for Public Policy: Use Cases, Gaps, and Research Directions,» 27 10 2020. [En línea]. Available: <https://arxiv.org/abs/2010.14374>. [Último acceso: 19 01 2021].
- [20] W. Samek, T. Wiegand, Müller y Klaus-Robert, «Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models,» 28 08 2017. [En línea]. Available: <https://arxiv.org/abs/1708.08296>. [Último acceso: 10 02 2021].
- [21] B. Barr, K. Xu, C. Silva, E. Bertini, R. Reilly, C. B. Bruss y J. D. Wittenbach, «Towards Ground Truth Explainability on Tabular Data,» 20 07 2020. [En línea]. Available: <https://arxiv.org/abs/2007.10532>. [Último acceso: 26 01 2021].
- [22] G. S. Z. L. Hoggarth, «Stress test of UK banks using VAR approach,» Bank of England, London, 2005.
- [23] P. Perron, «Trend, Unit Root and Structural Change in Macroeconomic Time Series,» p. 113, 1994.
- [24] C. M. Jarque y A. K. Bera, «A test for normality of observations and regression residuals,» *International Statistical Review* 55, pp. 163-172, 1987.
- [25] M. Hassoun, Fundamentals of Artificial Neural Networks, MIT Press, 1995.
- [26] C. Lorentzen y M. Mayer, «Peeking into the Black Box: An Actuarial Case Study for Interpretable Machine Learning,» Swiss Association of Actuaries SAV, 2020.
- [27] J. B. Gray y G. Fan, «Classification tree analysis using TARGET,» *Computational Statistics and Data Analysis*, pp. 1362-1372, 2008.
- [28] M. Ariza-Garzón, J. J. Arroyo, A. Caparrini y S.-V. Maria-Jesus, «Explainability of a Machine Learning Granting Scoring Model in Peer-to-Peer Lending,» *IEEE*, pp. 64873- 64890, 2020.