

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE CIENCIAS

MAESTRÍA EN RIESGO FINANCIERO

**PROPUESTA DE UN NUEVO MÉTODO DE CÁLCULO
NORMATIVO PARA ESTIMAR EL REQUERIMIENTO MÍNIMO
POR RIESGO DE LIQUIDEZ.**

TESIS DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE MAGISTER
EN RIESGO FINANCIERO

Roberto Javier Castellanos Reyes
javiercasrey@hotmail.com

DIRECTORA: Ing. Ruth Mariela Pazmiño Barreno. M.Sc.
ruthpazminob@gmail.com

CO-DIRECTOR: Dr. Ramiro Daniel Torres Gordillo
ramirotorres66@hotmail.com

Quito, Mayo 2015

DECLARACIÓN

Yo, ROBERTO JAVIER CASTELLANOS REYES, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación personal; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Escuela Politécnica Nacional, puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad vigente.

A handwritten signature in blue ink, appearing to read 'Roberto Castellanos R.', enclosed within a large, loopy blue oval stroke.

Roberto Javier Castellanos Reyes

CERTIFICACIÓN

Certifico que el presente trabajo fue desarrollado por Roberto Javier Castellanos Reyes, bajo mi supervisión.

A handwritten signature in blue ink, appearing to read 'Ruth Mariela Pazmiño Barreno', with a horizontal line underneath.

Ing. Ruth Mariela Pazmiño Barreno. M.Sc.
DIRECTORA DE LA TESIS DE GRADO

A handwritten signature in blue ink, appearing to read 'Dr. Ramiro Daniel Torres Gordillo', with a horizontal line underneath.

Dr. Ramiro Daniel Torres Gordillo
CO-DIRECTOR DE LA TESIS DE GRADO

AGRADECIMIENTOS

Mi gratitud y reconocimiento para la Ing. Ruth Mariela Pazmiño Barreno M.Sc. y al Dr. Ramiro Daniel Torres Gordillo, por supervisar esta Tesis, su confianza y apoyo profesional fueron determinantes en el desarrollo de este proyecto para concluir mis estudios de Postgrado.

DEDICATORIA

A mi familia soporte humano que me han apoyado en mis proyectos de vida, y que han sido la motivación para trabajar por mis metas personales y profesionales.

Contenido

INTRODUCCIÓN	xvii
1 GENERALIDADES DE LA INVESTIGACIÓN	1
1.1. PLANTEAMIENTO DEL PROBLEMA	1
1.2. OBJETIVOS DE LA INVESTIGACIÓN	3
1.2.1. OBJETIVO GENERAL	3
1.2.2. OBJETIVOS ESPECÍFICOS	3
1.3. HIPÓTESIS DE TRABAJO	3
1.4. TIPOLOGÍA DE LA INVESTIGACIÓN	4
2 MARCO TEÓRICO Y CONCEPTUAL DEL RIESGO DE LIQUIDEZ	5
2.1. ASPECTOS NORMATIVOS DEL SISTEMA FINANCIERO ECUATORIANO	5
2.2. METODOLOGÍAS AVANZADAS DE RIESGO DE LIQUIDEZ	8
2.2.1. RETIROS EN RIESGO	8
2.2.2. LIQUIDEZ EN RIESGO	9
2.2.3. FLUJO DE CAJA EN RIESGO	9
2.3. METODOLOGÍAS Y MODELOS DE CUANTIFICACIÓN APLICADOS EN RIESGO FINANCIERO	10
2.3.1. METODOLOGÍA DE VALOR EN RIESGO (VaR)	11
2.3.2. MODELOS DE SERIES DE TIEMPO: MEDIA Y VARIANZA CONDICIONAL	15
2.3.3. MODELOS DE DEPENDENCIA NO LINEAL: CÓPULAS	21
3 MODELO PROPUESTO PARA MEDIR EL RETIRO EN RIESGO	30
3.1. INFORMACIÓN ANALIZADA	30
3.1.1. SOFTWARE ESTADÍSTICO Y LIBRERÍAS	31
3.2. REVISIÓN DEL MÉTODO ACTUAL: LIQUIDEZ ESTRUCTURAL	32
3.2.1. MÉTODO DE LA VOLATILIDAD PROMEDIO PONDERADA	33

3.2.2.	MÉTODO DEL VALOR EN RIESGO	34
3.2.3.	RESULTADOS: INDICADORES DE LIQUIDEZ	35
3.3.	ESQUEMA DEL MODELO PROPUESTO	35
3.4.	DEFINICIÓN DEL PARÁMETRO DE MEDIDA	42
3.5.	SELECCIÓN Y CREACIÓN DE VARIABLES	42
4	MODELO PARA LA MEDIA Y VARIANZA CONDICIONAL	44
4.1.	PRUEBA DE RAÍCES UNITARIAS	44
4.1.1.	RAÍCES UNITARIAS: DEPÓSITOS CORRIENTE	45
4.1.2.	RAÍCES UNITARIAS: DEPÓSITOS A PLAZO	48
4.1.3.	RAÍCES UNITARIAS: DEPÓSITOS AHORROS	51
4.2.	MEDIA CONDICIONAL: DEPÓSITOS CORRIENTE	54
4.2.1.	MODELO ARMA: LOGARITMO DE LA SERIE DEPÓSITOS CORRIENTE	57
4.2.2.	PRUEBA ESTADÍSTICA DE BOX PIERCE - LJUNG BOX	58
4.2.3.	AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO ARMA	59
4.2.4.	PRUEBAS DE NORMALIDAD DE LOS ERRORES	62
4.2.5.	SELECCIÓN DEL MEJOR MODELO: DEPÓSITOS CORRIENTE	63
4.2.6.	PREDICCIÓN DE LA SERIE DEPÓSITOS CORRIENTE	64
4.3.	MEDIA CONDICIONAL: DEPÓSITOS A PLAZO	65
4.3.1.	MODELO ARMA: LOGARITMO DE LA SERIE DEPÓSITOS A PLAZO	68
4.3.2.	PRUEBA ESTADÍSTICA DE BOX PIERCE - LJUNG BOX	68
4.3.3.	AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO ARMA	70
4.3.4.	PRUEBAS DE NORMALIDAD DE LOS ERRORES	73
4.3.5.	SELECCIÓN DEL MEJOR MODELO: DEPÓSITOS A PLAZO	74
4.3.6.	PREDICCIÓN DE LA SERIE DEPÓSITOS A PLAZO	75
4.4.	MEDIA Y VARIANZA CONDICIONAL: AHORROS	76
4.4.1.	MODELO ARMA: LOGARITMO AHORROS	79
4.4.2.	PRUEBA ESTADÍSTICA DE BOX PIERCE - LJUNG BOX	79

4.4.3.	AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO ARIMA	81
4.4.4.	PRUEBAS DE NORMALIDAD DE LOS ERRORES	83
4.4.5.	MODELO GARCH PARA LA VARIANZA CONDICIONAL: LOGARITMO DE LA SERIE DEPÓSITOS AHORROS	84
4.4.6.	PRUEBA DE BOX PIERCE - LJUNG BOX PARA LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO GARCH	85
4.4.7.	AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO GARCH	87
4.4.8.	PRUEBAS DE NORMALIDAD DE LOS ERRORES DEL MODELO GARCH(1,1) DE LA SERIE DEPÓSITOS DE AHORROS	89
4.4.9.	SELECCIÓN DEL MEJOR MODELO: DEPÓSITOS A PLAZO	90
4.4.10.	PREDICCIÓN DE LA SERIE DEPÓSITOS AHORROS	91
5	MODELO DE DEPENDENCIA NO LINEAL	94
5.1.	PRUEBAS DE BONDAD DE AJUSTE	95
5.1.1.	PRUEBAS DE BONDAD DE AJUSTE DE LAS MARGINALES	95
5.1.2.	PRUEBAS DE AJUSTE SOBRE LAS FUNCIONES DE CADA RESIDUO	96
5.1.3.	PRUEBAS DE AJUSTE DE LAS PROBABILIDADES A UNA DISTRIBUCIÓN UNIFORME	97
5.2.	PRUEBAS DE INDEPENDENCIA	97
5.3.	PRUEBAS DE BONDAD DE AJUSTE: CÓPULAS ARQUIMEDIANAS	100
5.4.	PRUEBAS DE BONDAD DE AJUSTE: CÓPULAS ELÍPTICAS	103
5.5.	CONSTRUCCIÓN DE LOS MODELOS CÓPULA	106
6	METODOLOGÍA PARA GESTIONAR EL RETIRO EN RIESGO	111
6.1.	SIMULACIÓN DE NÚMEROS ALEATORIOS EN FUNCIÓN DE LAS CÓPULAS DE GUMBEL, FRANK, NORMAL Y t	111

6.2. ESTIMACIÓN DEL PARÁMETRO DE RETIRO INDIVIDUAL DE CADA FUENTE DE FONDEO	114
6.3. ESTIMACIÓN DEL RETIRO GLOBAL	116
6.4. CÁLCULO DEL RETIRO GLOBAL FINAL	117
6.4.1. FACTOR DE COBERTURA DE LIQUIDEZ	118
6.4.2. METODOLOGÍA PARA ESTIMAR EL FLUJO DE COBERTURA DE LIQUIDEZ DIARIO	120
6.4.3. RESULTADOS DE LA METODOLOGÍA PARA ESTIMAR EL RETIRO GLOBAL FINAL	120
7 CONCLUSIONES Y RECOMENDACIONES	124
7.1. CONCLUSIONES	124
7.2. RECOMENDACIONES	128
Bibliografía	131
Anexos	133
A MODELOS DE SERIES DE TIEMPO QUE NO FUERON SELECCIONADOS: DEPÓSITOS CORRIENTE	134
A.1. MODELO 1: Arima(1,0,0) con b_0	134
A.2. MODELO 2: Arima(1,0,0)(1,1,0) sin b_0	140
A.3. MODELO 3: Arima(2,0,0)(1,1,0) sin b_0	146
A.4. MODELO 4: Arima(2,0,0)(2,1,0) sin b_0	152
A.5. MODELO 5: Arima(1,0,0)(0,0,0) sin b_0 (log corriente)	158
A.6. MODELO 6: Arima(1,0,0)(1,1,0) sin b_0 (log corriente)	164
A.7. MODELO 7: Arima(2,0,0)(1,1,0) sin b_0 (log corriente)	170
B MODELOS DE SERIES DE TIEMPO QUE NO FUERON SELECCIONADOS: DEPÓSITOS A PLAZO	177
B.1. MODELO 1: Arima(1,0,0)(0,0,0) con b_0	177
B.2. MODELO 2: Arima(1,0,0)(1,1,0) sin b_0	183
B.3. MODELO 3: Arima(2,0,0)(1,1,0) sin b_0	189
B.4. MODELO 4: Arima(2,0,0)(2,1,0) sin b_0	195
B.5. MODELO 5: Arima(1,0,0)(0,0,0) sin b_0 (log a plazo)	201
B.6. MODELO 6: Arima(1,0,0)(1,1,0) sin b_0 (log a plazo)	207

B.7. MODELO 7: Arima(2,0,0)(1,1,0) sin b0 (log a plazo)	213
C MODELOS DE SERIES DE TIEMPO QUE NO FUERON SELECCIONADOS: DEPÓSITOS DE AHORROS	220
C.1. MODELO 1: Arima(1,0,0)(0,0,0) con b0	220
C.2. MODELO 2: Arima(1,0,0)(1,1,0) sin b0	226
C.3. MODELO 3: Arima(2,0,0)(1,1,0) sin b0	232
C.4. MODELO 4: Arima(2,0,0)(2,1,0) sin b0	238
C.5. MODELO 5: Arima(1,0,0)(0,0,0) con b0 (log ahorros)	244
C.6. MODELO 6: Arima(1,0,0)(0,0,0) sin b0 (log ahorros)	250
C.7. MODELO 7: Arima(1,0,0)(1,1,0) sin b0 (log ahorros)	256
D ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA CADA SERIE DE DEPÓSITOS ANALIZADA PARA SU RESPECTIVA CÓPULA	263
D.1. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA DE GUMBEL	263
D.2. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA DE FRANK	264
D.3. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA NORMAL	265
D.4. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA t	265
D.5. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS A PLAZO CON LA CÓPULA DE GUMBEL	266
D.6. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS A PLAZO CON LA CÓPULA DE FRANK	267
D.7. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS A PLAZO CON LA CÓPULA NORMAL	268
D.8. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS A PLAZO CON LA CÓPULA t	269
D.9. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA DE GUMBEL	269
D.10. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA DE FRANK	270

D.11. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA NORMAL	271
D.12. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA t	272
E GLOSARIO DE TÉRMINOS	274

Índice de figuras

2.1. Reportes de liquidez normativos	6
2.2. Simulación números aleatorios $N(0,1)$	16
2.3. Metodología de Box-Jenkins	20
3.1. Base de datos y definición de parámetro de medida	37
3.2. Modelo de autocorrelación: arima - garch	38
3.3. Modelo de correlación no lineal: Cópulas	39
3.4. Estimación del valor de retiro en riesgo	40
3.5. Pruebas retrospectivas de calibración	41
4.1. Serie depósitos corriente	55
4.2. Serie logaritmo depósitos corriente	56
4.3. Residuos del modelo arma(1,0) de log. corriente	60
4.4. Residuos al cuadrado del modelo arma(1,0) de log. corriente	61
4.5. Histograma de residuales y Gráfico Q-Q de residuales	63
4.6. Predicción serie depósitos corriente	65
4.7. Serie depósitos a plazo	66
4.8. Serie logaritmo depósitos a plazo	67
4.9. Gráfico de los residuos del modelo arma(1,0)	71
4.10. Gráfico de los residuos al cuadrado del modelo arma(1,0)	72
4.11. Histograma de residuales y Gráfico Q-Q de residuales	74
4.12. Predicción serie depósitos a plazo	76
4.13. Serie depósitos ahorros	77
4.14. Serie logaritmo depósitos ahorros	78
4.15. Gráfico de los residuos del modelo arima(2,0,0)(1,1,0)	81
4.16. Gráfico de los residuos al cuadrado del modelo arima(2,0,0)(1,1,0)	82
4.17. Histograma de residuales y Gráfico Q-Q de residuales	84
4.18. Gráfico de los residuos del modelo GARCH(1,1)	87
4.19. Gráfico de los residuos al cuadrado del modelo GARCH(1,1)	88

4.20. Histograma y Gráfico Q-Q de residuales modelo GARCH(1,1)	90
4.21. Predicción serie depósitos ahorros	93
5.1. Gráfico en 3 dimensiones de la cópula de Gumbel	107
5.2. Gráfico en 3 dimensiones de la cópula de Frank	108
5.3. Gráfico en 3 dimensiones de la cópula Normal	108
5.4. Gráfico en 3 dimensiones de la cópula t	109
6.1. Cópula de Gumbel	112
6.2. Cópula de Frank	112
6.3. Cópula Normal	113
6.4. Cópula t	113
6.5. Gráfico de la prueba de validación diaria	121
7.1. Esquema de administración del riesgo de liquidez	125
A.1. Gráfico de la serie depósitos corriente versus los valores ajustados para el modelo ARIMA(1,0,0)	135
A.2. Gráfico de la serie depósitos corriente versus los valores ajustados para el modelo ARIMA(1,0,0)(1,1,0)	141
A.3. Gráfico de la serie depósitos corriente versus los valores ajustados para el modelo ARIMA(2,0,0)(1,1,0)	147
A.4. Gráfico de la serie depósitos corriente versus los valores ajustados para el modelo ARIMA(2,0,0)(2,1,0)	153
A.5. Gráfico de la serie logaritmo depósitos corriente versus los valores ajustados para el modelo ARIMA(1,0,0)(0,0,0)	159
A.6. Gráfico de la serie logaritmo depósitos corriente versus los valores ajustados para el modelo ARIMA(1,0,0)(1,1,0)	165
A.7. Gráfico de la serie logaritmo depósitos corriente versus los valores ajustados para el modelo ARIMA(2,0,0)(1,1,0)	171
B.1. Gráfico de la serie depósitos a plazo versus los valores ajustados para el modelo ARIMA(1,0,0)(0,0,0)	178
B.2. Gráfico de la serie depósitos a plazo versus los valores ajustados para el modelo ARIMA(1,0,0)(1,1,0)	184
B.3. Gráfico de la serie depósitos a plazo versus los valores ajustados para el modelo ARIMA(2,0,0)(1,1,0)	190

B.4. Gráfico de la serie depósitos a plazo versus los valores ajustados para el modelo $ARIMA(2,0,0)(2,1,0)$	196
B.5. Gráfico de la serie logaritmo depósitos a plazo versus los valores ajustados para el modelo $ARIMA(1,0,0)(0,0,0)$	202
B.6. Gráfico de la serie logaritmo depósitos a plazo versus los valores ajustados para el modelo $ARIMA(1,0,0)(1,1,0)$	208
B.7. Gráfico de la serie logaritmo depósitos a plazo versus los valores ajustados para el modelo $ARIMA(2,0,0)(1,1,0)$	214
C.1. Gráfico de la serie depósitos ahorros versus los valores ajustados para el modelo $ARIMA(1,0,0)(0,0,0)$	221
C.2. Gráfico de la serie depósitos ahorros versus los valores ajustados para el modelo $ARIMA(1,0,0)(1,1,0)$	227
C.3. Gráfico de la serie depósitos ahorros versus los valores ajustados para el modelo $ARIMA(2,0,0)(1,1,0)$	233
C.4. Gráfico de la serie depósitos ahorros versus los valores ajustados para el modelo $ARIMA(2,0,0)(2,1,0)$	239
C.5. Gráfico de la serie logaritmo depósitos ahorros versus los valores ajustados para el modelo $ARIMA(1,0,0)(0,0,0)$	245
C.6. Gráfico de la serie logaritmo depósitos ahorros versus los valores ajustados para el modelo $ARIMA(1,0,0)(0,0,0)$	251
C.7. Gráfico de la serie logaritmo depósitos ahorros versus los valores ajustados para el modelo $ARIMA(1,0,0)(1,1,0)$	257

Índice de tablas

2.1. Medidas de dependencia para las cópulas Elípticas	26
2.2. Medidas de dependencia para las cópulas de Arquímedes	29
3.1. Desviación estándar de los depósitos analizados	33
3.2. Indicadores de liquidez estructural	35
3.3. Estadísticas descriptivas del nuevo parámetro de medida	43
4.1. Corriente: estadístico Tau y valores críticos 1 %, 5 % y 10 %	46
4.2. Corriente: modelo con tendencia y constante	47
4.3. Corriente: modelo con constante	47
4.4. Corriente: modelo sin tendencia ni constante	47
4.5. Corriente: prueba Loglikelihood, Akaike y Schwarz	47
4.6. Plazo: estadístico Tau y valores críticos 1 %, 5 % y 10 %	49
4.7. Plazo: modelo con tendencia y constante	50
4.8. Plazo: modelo con constante	50
4.9. Plazo: modelo sin tendencia ni constante	50
4.10. Plazo: prueba Loglikelihood, Akaike y Schwarz	51
4.11. Ahorros: estadístico Tau y valores críticos 1 %, 5 % y 10 %	53
4.12. Ahorros: modelo con tendencia y constante	53
4.13. Ahorros: modelo con constante	53
4.14. Ahorros: modelo sin tendencia ni constante	54
4.15. Ahorros: prueba Loglikelihood, Akaike y Schwarz	54
4.16. Autocorrelación y Autocorrelación Parcial: depósitos corriente	55
4.17. Autocorrelación y Autocorrelación Parcial: log. depósitos corriente	56
4.18. Prueba de Box Pierce - Ljung Box: Log. depósitos corriente	58
4.19. Prueba de Box Pierce - Ljung Box: Residuos depósitos corriente	58
4.20. Prueba de Box Pierce - Ljung Box: Residuos al cuadrado depósitos corriente	59
4.21. Autocorrelación y Autocorrelación Parcial: Residuos	60

4.22. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado . . .	61
4.23. Autocorrelación y Autocorrelación Parcial: Serie depósitos a plazo . .	66
4.24. Autocorrelación y Autocorrelación Parcial: Serie log. depósitos plazo	67
4.25. Prueba de Box Pierce - Ljung Box: Log. depósitos a plazo	69
4.26. Prueba de Box Pierce - Ljung Box: Residuos depósitos a plazo . . .	69
4.27. Prueba de Box Pierce - Ljung Box: Residuos al cuadrado depósitos a plazo	70
4.28. Autocorrelación y Autocorrelación Parcial: Residuos	71
4.29. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado . .	72
4.30. Autocorrelación y Autocorrelación Parcial: Serie depósitos ahorros .	77
4.31. Autocorrelación y Autocorrelación Parcial: Logaritmo ahorros	78
4.32. Prueba de Box Pierce - Ljung Box: Log. depósitos ahorros	80
4.33. Prueba de Box Pierce - Ljung Box: Residuos depósitos ahorros . . .	80
4.34. Prueba de Box Pierce - Ljung Box: Residuos al cuadrado dep. ahorros	80
4.35. Autocorrelación y Autocorrelación Parcial: Residuos	82
4.36. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado . .	83
4.37. Prueba de Box Pierce - Ljung Box: Residuos del modelo GARCH de ahorros	86
4.38. Prueba de Box Pierce - Ljung Box: Residuos al cuadrado del modelo GARCH de ahorros	86
4.39. Autocorrelación y Autocorrelación Parcial: Residuos	88
4.40. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado . .	89
5.1. Pruebas de bondad de ajuste de las marginales	95
5.2. Mínimos y máximos de las probabilidades de los residuos	96
5.3. Pruebas de ajuste de las probabilidades a una distribución uniforme	97
5.4. Resumen pruebas de independencia	100
5.5. Resumen cópulas ARQUIMEDIANAS	103
5.6. Resumen cópulas ELÍPTICAS	106
6.1. Resultados del modelo: porcentajes de retiro	115
6.2. Índices de retiro	122
6.3. Indicadores de liquidez estructural, normativa vigente SB	122
6.4. Cobertura del retiro estimado versus el retiro real	123

A.1. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)	136
A.2. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)	136
A.3. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente	137
A.4. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie de depósitos corriente	138
A.5. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)	142
A.6. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)	142
A.7. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente	143
A.8. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie de depósitos corriente	144
A.9. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)	148
A.10. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)	148
A.11. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente	149
A.12. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie de depósitos corriente	150
A.13. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(2,1,0)	154
A.14. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(2,1,0)	154
A.15. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente	155
A.16. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie de depósitos corriente	156
A.17. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)	160

A.18. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo $ARIMA(1,0,0)(0,0,0)$	160
A.19. Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo depósitos corriente	161
A.20. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo depósitos corriente	162
A.21. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo $ARIMA(1,0,0)(1,1,0)$	166
A.22. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo $ARIMA(1,0,0)(1,1,0)$	166
A.23. Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo depósitos corriente	167
A.24. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo depósitos corriente	168
A.25. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo $ARIMA(2,0,0)(1,1,0)$	172
A.26. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo $ARIMA(2,0,0)(1,1,0)$	172
A.27. Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo depósitos corriente	173
A.28. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo depósitos corriente	174
B.1. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo $ARIMA(1,0,0)(0,0,0)$	179
B.2. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo $ARIMA(1,0,0)(0,0,0)$	179
B.3. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo	180
B.4. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo	181
B.5. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo $ARIMA(1,0,0)(1,1,0)$	185
B.6. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo $ARIMA(1,0,0)(1,1,0)$	185

B.7. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo	186
B.8. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo	187
B.9. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)	191
B.10. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)	191
B.11. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo	192
B.12. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo	193
B.13. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(2,1,0)	197
B.14. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(2,1,0)	197
B.15. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo	198
B.16. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo	199
B.17. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)	203
B.18. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)	203
B.19. Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos a plazo	204
B.20. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos a plazo	205
B.21. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)	209
B.22. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)	209
B.23. Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos a plazo	210

B.24. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos a plazo	211
B.25. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)	215
B.26. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)	215
B.27. Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos a plazo	216
B.28. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos a plazo	217
C.1. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)	222
C.2. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)	222
C.3. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros	223
C.4. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos ahorros	224
C.5. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)	228
C.6. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)	228
C.7. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros	229
C.8. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos ahorros	230
C.9. Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)	234
C.10. Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)	234
C.11. Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros	235
C.12. Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos ahorros	236

C.13.Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(2,1,0)	240
C.14.Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(2,1,0)	240
C.15.Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros	241
C.16.Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie de depósitos ahorros	242
C.17.Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)	246
C.18.Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)	246
C.19.Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos ahorros	247
C.20.Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie logaritmo de depósitos ahorros	248
C.21.Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)	252
C.22.Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)	252
C.23.Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos ahorros	253
C.24.Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie logaritmo de depósitos ahorros	254
C.25.Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)	258
C.26.Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)	258
C.27.Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos ahorros	259
C.28.Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, se- rie logaritmo de depósitos ahorros	260

INTRODUCCIÓN

Según el Comité de Basilea, el manejo de la liquidez es la actividad más importante que realiza una institución financiera, dado que incluye en su administración el resto de los riesgos financieros y operativos; y, principalmente es un riesgo que potencialmente puede exponer a la organización a una potencial quiebra por iliquidez e insolvencia.

Por lo tanto, es necesario revisar si el parámetro de medida planteado actualmente en la normativa de liquidez, guarda concordancia con la necesidad de mantener un nivel mínimo de activos líquidos para cubrir las obligaciones pactadas con los clientes, durante un horizonte de tiempo determinado; adicionalmente, se requiere desarrollar metodologías de modelización más avanzadas que permitan mejorar el ajuste de las estimaciones de la volatilidad, que consideren factores como la no normalidad de los datos, la correlación no lineal entre las fuentes de fondeo, así como el carácter estocástico y dinámico del comportamiento de la liquidez estructural.

Con este enfoque, esta investigación beneficiará en primera instancia la regulación asociada al Marco Normativo del Riesgo de Liquidez y consecuentemente el Sistema Financiero regulado del país, dado que se fortalecerán los métodos de cuantificación de este riesgo financiero, de tal forma que los supervisores bancarios y las entidades financieras, podrán contar con información y reportes de liquidez más consistentes y transparentes, que permitan establecer mecanismos de alerta temprana para medir, controlar y monitorear las operaciones bancarias de inversión, colocación y financiamiento. Además, con esto se estará beneficiando indirectamente a los depositantes del Sistema Financiero, al precautelar de forma más eficiente sus depósitos, sean estos a la vista o a plazo.

Capítulo 1

GENERALIDADES DE LA INVESTIGACIÓN

1.1. PLANTEAMIENTO DEL PROBLEMA

Con respecto a la estimación del requerimiento mínimo de liquidez por volatilidad de las fuentes de fondeo, en octubre del año 2004, la Superintendencia de Bancos y Seguros emitió un instructivo para la aplicación del Concepto de Valor en Riesgo (VaR), para la estimación de la volatilidad no diversificada de las fuentes de fondeo. Con este insumo se determina, la volatilidad general que resulta del cociente entre el Valor en Riesgo (VaR) dividido para la sumatoria de los saldos de la fuentes de fondeo en el día que se está estimando el Valor en Riesgo (VaR). Finalmente, los indicadores de liquidez estructural de primera y segunda línea son equivalentes a multiplicar la volatilidad general, por un factor de 2 y 2.5 veces, respectivamente.

En diciembre del año 2004, la Superintendencia de Bancos y Seguros emitió una circular aclaratoria, Circular No. SBS-INIF-DNR-DRF-2004-3900, con fecha 14 de diciembre de 2004, dado que ya se habían identificado algunas inconsistencias en la metodología propuesta del Valor en Riesgo, en la cual se mencionaba que la variación logarítmica se aplicaba sin problemas cuando los saldos de las cuentas son distintos de cero, sin embargo, cuando los saldos del numerador y del denominador son cero, no se puede calcular ni el cociente ni el logaritmo del mismo; por otro lado, si el numerador es igual a cero y el denominador mayor que cero la tasa tendría un valor infinito negativo, caso contrario, si el numerador es mayor que cero y el denominador es igual a cero, la tasa tendría un valor infinito positivo.

Con este antecedente, se instruyó al Sistema Financiero, que en el caso que se presenten saldos de cero, se asuma una tasa de variación logarítmica

de cero y para los otros dos casos, en el que el numerador o el denominador sean iguales a cero asumir como que registraron el valor de USD 1.

Posteriormente, en agosto del año 2005, se efectuaron algunos ajustes a esta metodología, dado que para el cálculo de la volatilidad se estaba utilizando una serie de valores que corresponden a las denominadas tasas de variación continua en períodos de 30 días, pero en la determinación de los requerimientos mínimos se las consideraba como si fueran tasas de variación discretas; adicionalmente, el cálculo de la desviación estándar, asignaba el mismo peso a todos los datos de la serie, sin importar la temporalidad de ocurrencia. También es importante mencionar que esta metodología considera que la parte volátil de los pasivos puede ser un ingreso o un egreso de fondos; es decir, que un valor positivo indica en qué porcentaje disminuyeron los pasivos y un valor negativo refleja el porcentaje en que crecieron los pasivos.

Por lo tanto, los requerimientos mínimos corresponden a una medida de la volatilidad de los pasivos exigibles, y se determinan aplicando un modelo estadístico en base a la observación de su comportamiento a través del tiempo; sin embargo, surge el cuestionamiento de si el parámetro de medida sobre el cual se está aplicando el modelo estadístico está bien definido, con el referente que un incremento de los ingresos de las fuentes de fondeo no implica que se tenga un mayor riesgo de liquidez, dado que conceptualmente el riesgo de liquidez viene dado por la deficiencia de activos líquidos para cubrir las obligaciones, entendiéndose por obligación el evento cuando un cliente desea retirar sus depósitos.

De los síntomas y causas hasta aquí presentados, se tiene que, dado que no existe una método o modelo de cálculo consistente para estimar el riesgo de liquidez en el Sistema Financiero; y, considerando que la fase de medición es determinante en el proceso de gestión de riesgos para posteriormente tener una adecuada mitigación y control del riesgo, podrían generarse situaciones atípicas o de estrés de la economía y finanzas del país, en que las Entidades no cuenten con una cobertura suficiente de liquidez, problemas de iliquidez los cuales derivarían en problemas de insolvencia, impactando directamente a la estabilidad y normal desarrollo de las Instituciones Financieras.

Consecuentemente, es necesario determinar un método de cálculo para estimar el requerimiento mínimo de liquidez por volatilidad, replanteando el parámetro de medida sobre el cual debería cuantificarse el riesgo de liquidez, entendiéndose que éste debe cubrir el evento que los depositantes retiren parte o todos sus depósitos durante un horizonte de tiempo determinado.

1.2. OBJETIVOS DE LA INVESTIGACIÓN

1.2.1. OBJETIVO GENERAL

Establecer un nuevo método de cálculo para estimar el requerimiento mínimo por riesgo de liquidez en función de la volatilidad de los depósitos.

1.2.2. OBJETIVOS ESPECÍFICOS

- Analizar las metodologías que hasta el momento ha planteado la Superintendencia de Bancos y Seguros para cuantificar el riesgo de liquidez estructural, contractual, esperado y dinámico; así como la propuesta de modelos internos estadístico - matemáticos que se han definido en los acuerdos de Basilea y otras mejores prácticas de gestión de riesgo de liquidez desarrolladas en el contexto internacional.
- Formular un nuevo parámetro de medida que cuantifique la volatilidad del retiro de depósitos.
- Construir un nuevo método de cálculo que permita estimar el nivel mínimo de los activos líquidos de primera y segunda línea que requiere una institución financiera para cubrir eventuales disminuciones de sus fuentes de fondeo, considerando la volatilidad de los pasivos.
- Elaborar un esquema de administración del riesgo de liquidez en función de las estimaciones de los retiros de los depósitos, de acuerdo al horizonte temporal de la predicción.

1.3. HIPÓTESIS DE TRABAJO

- El cálculo de la parte volátil descrito en el instructivo para la aplicación del Concepto de Valor en Riesgo de la Superintendencia de Bancos y Segu-

ros, no está bien definido; es decir, la métrica de cálculo no es consistente con el concepto de riesgo de liquidez estructural, dado por el nivel de activos líquidos suficientes para cubrir una parte de los pasivos exigibles en el corto plazo.

- Se puede estimar estadísticamente la parte volátil de un grupo de depósitos en un horizonte temporal determinado, a través de modelos que no se fundamenten en distribuciones normales y correlaciones lineales entre las fuentes de fondeo.
- En función de las estimaciones de los retiros de los depósitos y de acuerdo al horizonte temporal de la predicción, se puede elaborar un esquema de administración del riesgo de liquidez.

1.4. TIPOLOGÍA DE LA INVESTIGACIÓN

La metodología que se aplicó en este trabajo de Tesis, está definida sobre la base de cuatro tipologías:

- I. Por su finalidad es del tipo aplicada, dado que su objetivo es generar conocimientos para la aplicación práctica dirigidos a la solución de problemas específicos.
- II. Por el alcance que tiene esta investigación, es explicativa; es decir, se busca identificar los factores que contribuyen para la ocurrencia de los fenómenos, enfocándose en el *¿por qué?* de las cosas y la forma como ocurren.
- III. Por el tipo de abordaje es cuantitativa, debido que los conceptos que se abordan en este estudio, requieren ser medidos y los resultados precisan ser replicados; sin embargo, tiene un componente cualitativo debido a que gran parte de la investigación se sustenta en un trabajo de investigación bibliográfica.
- IV. Por el lugar, este trabajo es de laboratorio, considerando que el levantamiento de datos no se efectuará por observación directa, sino que se reproducirá artificialmente el hecho o fenómeno estudiado que en este caso es el comportamiento del retiro de los depósitos volátiles.

Capítulo 2

MARCO TEÓRICO Y CONCEPTUAL DEL RIESGO DE LIQUIDEZ

2.1. ASPECTOS NORMATIVOS DEL SISTEMA FINANCIERO ECUATORIANO

En la nota técnica¹ [1] emitida por la Superintendencia de Bancos, se define al Riesgo de Liquidez como “la posibilidad de no poder hacer frente a las obligaciones de pago o que para hacerlo se incurra en costos excesivos” (p. 11); además, en esta nota técnica, se establecen dos puntos de vista a través de los cuales se cuantifican este riesgo:

- **RIESGO DE LIQUIDEZ ESTRUCTURAL.-** La medición estructural del riesgo de liquidez parte de considerar la composición de activos y pasivos líquidos en una posición estática a una fecha determinada y sobre los saldos contables. Esta posición estructural muestra líneas de liquidez comparables con su volatilidad, de tal manera que los activos líquidos muestren una cobertura frente a los requerimientos.
- **ANÁLISIS DE BRECHAS DE LIQUIDEZ.-** Este análisis parte de una fecha determinada y clasifica los flujos de capital e intereses de acuerdo a su vencimiento. El análisis se subdivide en tres escenarios: vencimientos contractuales, vencimientos esperados y análisis dinámico. En cada escenario se da un tratamiento especial a las cuentas con vencimiento cierto y a las cuentas con vencimiento incierto.

¹Nota técnica sobre riesgos de mercado y liquidez, emitida por la Superintendencia de Banco en el año 2002 a través de Resoluciones Nos. JB-2002-429 y JB-2002-431.

En la mencionada nota técnica [1] (p. 11), se presenta un esquema resumen de los reportes normativos que se utilizan para el control y monitoreo del comportamiento de la liquidez de las instituciones financieras, los cuales son descritos en la figura 2.1:

Análisis	Escenarios		Tratamiento de cuentas	
Estructura de activos y pasivos líquidos	Estático		No existe tratamiento de cuentas para el escenario estático	
Análisis de brechas	Estático	Contractual	Cuentas con vencimiento cierto	Al vencimiento
			Cuentas con vencimiento incierto	Supuestos o modelos de comportamiento
		Esperado	Cuentas con vencimiento cierto	Al vencimiento ajustado por supuestos o modelos de comportamiento
			Cuentas con vencimiento incierto	Supuestos o modelos de comportamiento
	Dinámico		Cuentas con vencimiento cierto	Al vencimiento ajustado por supuestos o modelos de comportamiento más elementos de planeación financiera
			Cuentas con vencimiento incierto	Supuestos o modelos de comportamiento más elementos de planeación financiera

Figura 2.1: Reportes de liquidez normativos

Los reportes de liquidez por bandas de tiempo, se pueden analizar a través de tres escenarios:

- **RIESGO DE LIQUIDEZ CONTRACTUAL.-** En este escenario las cuentas con vencimiento cierto se presentan al vencimiento. Las cuentas con vencimiento incierto deben ser tratadas sobre la base de supuestos sustentados en modelos de comportamiento, con soporte estadístico con un nivel de confianza mínimo del 90 % y una serie de tiempo de al menos 12 meses.
- **RIESGO DE LIQUIDEZ ESPERADO.-** En este escenario las cuentas con vencimiento cierto también son sometidas a ajustes sobre la base de supuestos sustentados en modelos de comportamiento que incorporen soportes estadísticos con un nivel de confianza mínimo del 90 % y una serie

de tiempo de al menos 12 meses. Tanto en el escenario contractual como en el esperado para los instrumentos financieros que aplique (cartera de crédito, inversiones, depósitos) se deberá incluir como parte del flujo a los intereses por percibir o aquellos por cancelar.

- **RIESGO DE LIQUIDEZ DINÁMICO.-** En este escenario se parte del análisis de liquidez esperado y además se incorporan elementos de proyecciones y de planeación financiera de la entidad. También en este escenario, sobre los instrumentos financieros que aplique (cartera de crédito, inversiones, depósitos) se deberá incluir como parte del flujo a los intereses por percibir o aquellos por cancelar.
- **LIQUIDEZ EN RIESGO.-** En la nota técnica² [1] (p. 12), se define que para el cálculo de la **liquidez en riesgo** no se colocarán los activos líquidos en ninguna banda en particular y para calcular la posición en riesgo de liquidez, se compararán con la brecha acumulada en cada banda de acuerdo, como se indica en la ecuación (2.1):

$$Liq.R = (|brecha acumulada de liquidez n < 0| - ALN) > 0 \quad (2.1)$$

Donde:

Liq. R = liquidez en riesgo.

n = nésima banda de tiempo y n = 1, 2, 3, ..., q; q es el número de bandas.

ALN es igual a los fondos disponibles más los fondos interbancarios netos más pactos de reventa menos pactos de recompra menos inversiones negociables.

En cualquier caso la Superintendencia de Bancos y Seguros podrá especificar límites para el tratamiento y asignación de plazos para las cuentas de vencimiento incierto y examinará los supuestos empleados para determinar la idoneidad de su aplicación a los reportes de supervisión exigidos, tanto respecto a los productos con vencimiento incierto como a los ajustes por comportamiento de los productos con vencimiento cierto. Los supuestos o modelos empleados podrán incorporar otras cualidades aparte de los resultados meramente estadísticos.

²En el artículo 4, sección III, capítulo IV de la Resolución No. JB-2002-431 de enero del 2002, se presenta la fórmula para calcular la liquidez en riesgo.

- **POSICIONES DE RIESGO Y PLANES DE CONTINGENCIA.-** En la nota técnica[1] (p. 12, 13, 14), se menciona que el comité responsable de riesgo de liquidez, deberá poner en ejecución su plan de contingencia si se determina una posición de liquidez en riesgo en la primera o segunda banda, actuando como un elemento mínimo de indicador de alerta.

Así también, dicho comité deberá precisar los parámetros a utilizarse para identificar los límites de la posición de liquidez en riesgo de la entidad; tales como, cambios en la volatilidad de los depósitos a la vista, concentración y cobertura mínima de liquidez frente a pasivos volátiles, entre otros que se identifiquen.

Para definir la porción volátil de las fuentes de fondeo, las entidades controladas deberán utilizar la metodología más apropiada, que se ajuste a la complejidad de sus productos. Sobre el escenario esperado las instituciones controladas deberán preparar un análisis de estrés calculado con la posición del peor escenario de ocurrencia basado en los supuestos y modelos de comportamiento.

2.2. METODOLOGÍAS AVANZADAS DE RIESGO DE LIQUIDEZ

2.2.1. RETIROS EN RIESGO

Según [Castillo Edgar, 2008][2] citado en [Aguirre Andrea, 2010][3] el método del Retiro en Riesgo, se basa fundamentalmente en los retiros de depósitos que tiene que enfrentar una institución financiera; y, se asocia que el evento de mantener o retirar los depósitos de una institución financiera, pueden seguir una Distribución de Bernoulli con media (p) donde p representaría la probabilidad de cancelación de los depósitos.

No obstante, se considera que esta metodología es aún un modelo básico de estimación del Valor en Riesgo, dado que presenta algunas limitaciones técnicas al no incluir en el modelo la autocorrelación y correlación no lineal entre las fuentes de fondeo que se están analizando. En párrafos posteriores de este marco teórico se profundizarán estos conceptos.

2.2.2. LIQUIDEZ EN RIESGO

En el trabajo presentado por [Aguirre Andrea, 2010][3], define a la Liquidez en Riesgo (LaR) como la “máxima salida de depósitos durante un horizonte de tiempo definido a un nivel de confianza especificado” (p. 69), y que “el problema de incertidumbre se puede resolver usando la medida de Liquidez en Riesgo, puesto que calcula las salidas netas de dinero que presenta el banco, mismas que no deberán exceder de un horizonte temporal predeterminado” (p. 69).

También se han desarrollado medidas basadas en coeficientes de concentración de la liquidez, como por ejemplo el trabajo realizado por [Maldonado Diego & Pazmiño Ruth, 2009][4] en el cual se analizó la concentración de un solo cliente o grupo de clientes, con el fin de establecer que existe una adecuada diversificación de los clientes que conforman una determinada fuente de fondeo; para el efecto, se utilizó el índice de concentración de Herfindahl - Hirschman, este concepto también es tratado en [Castillo Edgar, 2008][2].

Es importante considerar que esta medida de riesgo es complementaria al retiro en riesgo, dado que las fuentes de riesgo de liquidez, están dadas por la volatilidad y por la concentración de los retiros; es decir, los pasivos de una institución financiera pudieran no ser volátiles pero si presentar un alto riesgo de concentración, estos casos se dan en las depósitos a plazo o en los depósitos de fondeos empresariales o corporativos.

2.2.3. FLUJO DE CAJA EN RIESGO

Finalmente el Flujo de Caja en Riesgo (CFaR) mencionado también en el trabajo de [Aguirre Andrea, 2010][3], es una metodología más avanzada que el Valor en Riesgo y que pretende estimar la desviación dada por el flujo de dinero actual versus el valor proyectado ocasionada por las variaciones en los factores de riesgo; es decir, además de analizar la volatilidad de los retiros y la concentración de los depósitos de una institución financiera, se analiza el flujo de liquidez, dado por los ingresos y egresos que ocurrirán durante una ventana temporal determinada, que puede ser un día, una semana, un mes, un trimestre, etc.

Resumiendo, el Retiro en Riesgo y el Flujo de Caja en Riesgo plantean la estimación del riesgo de liquidez a través del método de Valor en Riesgo con la diferencia que el Flujo de Caja en Riesgo utiliza un horizonte de tiempo mayor y un conjunto de variables más completas que inciden en el comportamiento real y cotidiano de la gestión de liquidez y no únicamente el análisis de las fuentes de fondeo aisladamente. Mientras tanto, la Liquidez en Riesgo está enfocada únicamente a modelar la concentración de depósitos, basados en la probabilidad de retiro o no retiro; sin embargo, no se plantea cuanto es el valor monetario del retiro y el horizonte temporal en el que ocurriría esta salida de depósitos.

2.3. METODOLOGÍAS Y MODELOS DE CUANTIFICACIÓN APLICADOS EN RIESGO FINANCIERO

El único método normativo basado en sustentos estadístico - matemáticos, se describe en el instructivo para la aplicación del Concepto de Valor en Riesgo (**VaR**), que emitió la Superintendencia de Bancos y Seguros en el (2004), mediante Resolución de Junta Bancaria (Resolución No. JB-2006-885, 2006); en el cual, se define una metodología de cálculo del requerimiento mínimo de primera y segunda línea, estimada a través de la volatilidad.

Según [Artzner P., 1999][5], citado en [Plascencia Tania, 2010][6], define las siguientes propiedades para que una medida de riesgo pueda ser considerada como coherente: monotonicidad, relevancia, homogeneidad positiva, invarianza ante traslaciones y subaditividad.

También en [Plascencia Tania, 2010][6] se menciona a tres modelos como los más relevantes de entre todos los diversos modelos que se han desarrollado para gestión de riesgos; estos son: el modelo de Harry Markowitz que desarrolló la Teoría de la diversificación de la Cartera con el objeto de disminuir el riesgo, el modelo de Fisher Black y Myron Scholes que propusieron un modelo para valorar y cubrir opciones financieras y el modelo de **JP Morgan** que propuso el concepto de **Valor en Riesgo** fundamentándose en la Teoría de Probabilidad.

Es importante anotar que el desarrollo del modelo de Valor en Riesgo nació en aplicaciones afines a riesgo de mercado; para metodologías de riesgo de liquidez y riesgo de crédito, se han ido adaptando de acuerdo a los conceptos

particulares de cada riesgo, motivo por el cual han existido algunas inconsistencias en la aplicación del modelo VaR, el cual “proporciona las expectativas condicionales de pérdida por encima del VaR” (p. 8).

El principal problema de la metodología VaR, guarda relación con la hipótesis de que la distribución estadística de los retornos es normal; hipótesis que no se cumple en mucho de los casos, por el contrario son las excepciones las que se ajustan a este tipo de distribución.

Adicionalmente, otro de los supuestos que se asume en el cálculo del valor en riesgo VaR es que la correlación entre variables es lineal, hipótesis que en la actualidad está siendo cuestionada por teorías que se han investigado en los últimos años, tal como lo manifiesta [Torres Gabriel & Olarte Ana, 2009][7]. Una de ellas es la teoría de cópulas, que se enfoca en modelar la estructura de dependencia entre las variables de riesgo que se están analizando, sin necesidad de partir de supuestos sobre sus distribuciones marginales, con lo cual se pretende evitar la sobrestimación o subestimación del valor en riesgo del portafolio; por lo tanto, el concepto de Cópula es de gran ayuda para hacer frente a estos problemas.

2.3.1. METODOLOGÍA DE VALOR EN RIESGO (VaR)

Según la definición de [Lara Alfonso, 2008][8], se define al VaR como: “**...estima la pérdida máxima que podría registrar un portafolio en un intervalo de tiempo y con cierto nivel de probabilidad o confianza**”.

En el año de 1994, **JP Morgan** plantea el concepto de **Valor en Riesgo**, fundamentándose en la Teoría de Probabilidad; particularmente, con el objetivo de cuantificar el riesgo de mercado de instrumentos de un portafolio de inversiones.

Actualmente, la aplicación de la metodología de valor en riesgo se ha extendido al riesgo de crédito y al riesgo de liquidez, considerando las diferentes particularidades de los instrumentos que componen cada uno de estos riesgos.

TIPOS DE VALOR EN RIESGO (VaR): Considerando la correlación entre las variables analizadas, el valor en riesgo puede ser diversificado y no diversi-

ficado; a continuación se describe cada tipo de valor en riesgo, tomando como referencia los conceptos planteados por [Lara Alfonso, 2008][8]:

- **VALOR EN RIESGO NO DIVERSIFICADO.-** No toma en cuenta la correlación entre los n instrumentos de un portafolio; por lo tanto, el valor en riesgo total del portafolio, es igual a la suma aritmética del valor en riesgo individual de cada instrumento del portafolio; en las ecuaciones (2.2) y (2.3) se describe el cálculo del valor en riesgo no diversificado definido en [Lara Alfonso, 2008][8]:

$$VaR_i = \omega_i^2 * \sigma_i^2 \quad (2.2)$$

$$VaR_{ND} = \sum_{i=1}^n VaR_i \quad (2.3)$$

Donde:

VaR_i = valor en riesgo del instrumento (i) para $i = 1, 2, 3, \dots, n$.

ω_i^2 = peso al cuadrado de la posición del instrumento (i) con respecto al total de instrumentos del portafolio para $i = 1, 2, 3, \dots, n$.

σ_i^2 = volatilidad del instrumento (i) para $i = 1, 2, 3, \dots, n$.

VaR_{ND} = valor en riesgo no diversificado.

- **VALOR EN RIESGO DIVERSIFICADO.-** Considera la correlación entre los n instrumentos de un portafolio; por lo tanto, el valor en riesgo total del portafolio es igual a la suma aritmética del valor en riesgo individual de cada instrumento del portafolio menos la correlación entre los instrumentos del portafolio analizado; en las ecuaciones (2.4), (2.5) y (2.6), se describe el cálculo del valor en riesgo diversificado definido en [Lara Alfonso, 2008][8]:

$$VaR_i = \omega_i^2 * \sigma_i^2 \quad (2.4)$$

$$VaR_{ND} = \sum_{i=1}^n VaR_i \quad (2.5)$$

$$VaR_D = \left[VaR_{ND} * C * VaR_{ND}^T \right]^{\frac{1}{2}} \quad (2.6)$$

Donde:

VaR_i = valor en riesgo del instrumento (i) para $i = 1, 2, 3, \dots, n$.

ω_i^2 = peso al cuadrado de la posición del instrumento (i) con respecto al total de instrumentos del portafolio para $i = 1, 2, 3, \dots, n$.

σ_i^2 = volatilidad del instrumento (i) para $i = 1, 2, 3, \dots, n$.

VaR_{ND} = vector del valor en riesgo no diversificado.

VaR_{ND}^T = vector transpuesto del valor en riesgo no diversificado .

C = matriz de correlaciones (correlación lineal).

VaR_D = valor en riesgo diversificado.

Para el caso particular en el que analicen únicamente dos instrumentos, se obtiene la ecuación (2.7):

$$VaR_D = \omega_1^2 * \sigma_1^2 + \omega_2^2 * \sigma_2^2 + 2 * \omega_1 * \omega_2 * \rho_{12} * \sigma_1 * \sigma_2 \quad (2.7)$$

Se puede concluir que la metodología de valor en riesgo diversificado, se ajusta más a la realidad de la información, dado generalmente casi todas las variables de la naturaleza tienen algún nivel de correlación lineal o no lineal.

TIPOS DE METODOLOGÍAS PARA ESTIMAR EL VALOR EN RIESGO

(VaR): Se utilizan dos tipos de métodos para estimar el valor en riesgo: paramétrico y no paramétrico; a continuación se describe cada metodología, tomando como referencia los conceptos planteados por [Lara Alfonso, 2008][8]:

I. **MÉTODO PARAMÉTRICO.-** El supuesto principal de este método, es que los rendimientos del activo se distribuyen de acuerdo a una curva de densidad de probabilidad normal; sin embargo, en el mismo texto se manifiesta que "...en la práctica se ha observado que la mayoría de los activos no siguen un comportamiento estrictamente normal, sino que son aproximados a la curva normal".

- **DELTA NORMAL (VARIANZAS COVARIANZAS).-** Estima el valor en riesgo de un portafolio considerando los efectos de la diversificación, a través de la correlación entre los rendimientos de los activos analizados. La fórmula de cálculo está dada por las ecuaciones (2.8), (2.9) y (2.10):

$$VaR_p = F * S * \sigma_p * \sqrt{t} \quad (2.8)$$

$$\sigma_p = \sqrt{[\omega]^T \cdot [\Sigma] \cdot [\omega]} \quad (2.9)$$

$$[\Sigma] = [\sigma] \cdot [C] \cdot [\sigma] \quad (2.10)$$

Donde:

F = factor que define el nivel de confianza.

t = horizonte de tiempo para ajuste del VaR.

$[\omega]$ = vector de pesos de las posiciones del portafolio (n X 1).

$[\omega]^T$ = vector transpuesto de los pesos de las posiciones del portafolio (1 X n).

$[\Sigma]$ = matriz de varianza covarianza que incluye las correlaciones entre los valores del portafolio (n X n).

$[C]$ = matriz de correlaciones de los rendimientos de los activos del portafolio.

S = Valor del portafolio.

σ_p = volatilidad del portafolio (1 X 1).

- **SIMULACIÓN MONTECARLO.-** Consiste en la generación de números aleatorios para calcular el valor del portafolio generando escenarios. Este proceso se repite un gran número de veces (al menos 10,000 escenarios); posteriormente, a través de un histograma de frecuencias se determina la máxima pérdida para un nivel de confianza previamente definido.

II. **MÉTODO NO PARAMÉTRICO.-** En este método no necesariamente las observaciones de las variables analizadas, se distribuyen de acuerdo a una curva de densidad de probabilidad normal. Adicionalmente, no se requiere establecer como insumos de entrada en el modelo ningún tipo de parámetros asociados a una distribución de probabilidad, sino únicamente información histórica que a través de técnicas estadísticas computacionales de simulación permitan estimar los parámetros requeridos.

- **SIMULACIÓN HISTÓRICA.-** Este método consiste en utilizar un serie histórica de precios de la posición de riesgo para construir una serie de tiempo de precios y rendimientos simulados o hipotéticos, con el supuesto de que se ha conservado el portafolio durante el período de tiempo de la serie histórica.

2.3.2. MODELOS DE SERIES DE TIEMPO: MEDIA Y VARIANZA CONDICIONAL

Las series de tiempo se clasifican en estacionarias y no estacionarias, según se define en [Cayuela Luis & Justel Ana, 2012][9]:

Series Estacionarias.- Los valores de las series estacionarias oscilan alrededor de una media constante y la variabilidad con respecto a la media también permanece constante en el tiempo.

Series No Estacionarias.- Son series en las cuales la tendencia y/o variabilidad cambian en el tiempo. Los cambios en la media determinan una tendencia a crecer o decrecer a largo plazo, por lo que la serie no oscila alrededor de un valor constante. Los componentes de una serie no estacionarias son:

- **Componente Estacional:** Está relacionado a las oscilaciones periódicas que presente una serie temporal y que puede ser: anual, mensual, semanal, diaria, horaria, etc. A este tipo de series se las denomina **estacionales**.
- **Componente de Tendencia:** Cambios de crecimiento o decrecimiento en el tiempo con respecto a un valor medio.
- **Componente aleatorio:** Esta componente no responde a ningún patrón de comportamiento, sino que es el resultado de factores fortuitos o aleatorios que inciden de forma aislada en una serie de tiempo.

Proceso estocástico estacionario.- Según [Villavicencio Jhon, 2012][10], un proceso estocástico se dice que es estacionario si su media, varianza y covarianza son constantes en el tiempo; es decir, el valor de la covarianza entre dos periodos depende solamente de la distancia o rezago entre estos dos periodos de tiempo y no del tiempo en el cual se ha calculado la covarianza.

Sea X_t una serie de tiempo. X_t es un proceso estacionario si cumple con las propiedades descritas en (2.11), (2.12) y (2.13):

$$E(X_t) = E(X_{t+k}) = \mu \quad (2.11)$$

$$V(X_t) = V(X_{t+k}) = \sigma_2 \quad (2.12)$$

$$\gamma_k = E [(X_t - \mu)(X_{t+k} - \mu)] = \mu \quad (2.13)$$

Ruido Blanco.- Un tipo especial de proceso estocástico, es el denominado *ruido blanco* definido en [Fernández Adrián, 2010][11], se denota por ϵ_t ; las condiciones que debe cumplir el ruido blanco son descritas en (2.14), (2.15), (2.16) y (2.17) que fueron tomadas de [Uriel Ezequiel, 1985][12]:

$$E(\epsilon_t) = 0 \quad \forall t \quad (2.14)$$

$$V(\epsilon_t) = E(\epsilon_t^2) = \sigma^2 \quad \forall t \quad (2.15)$$

$$COV(\alpha_t, \alpha_s) = E(\alpha_t * \alpha_s) = 0 \quad \forall t \neq s \quad (2.16)$$

$$\epsilon_t \rightarrow N(0, \sigma^2) \quad \forall t; \text{ v.a.i.i.d} \quad (2.17)$$

A continuación, se presenta un ejemplo de ruido blanco³:

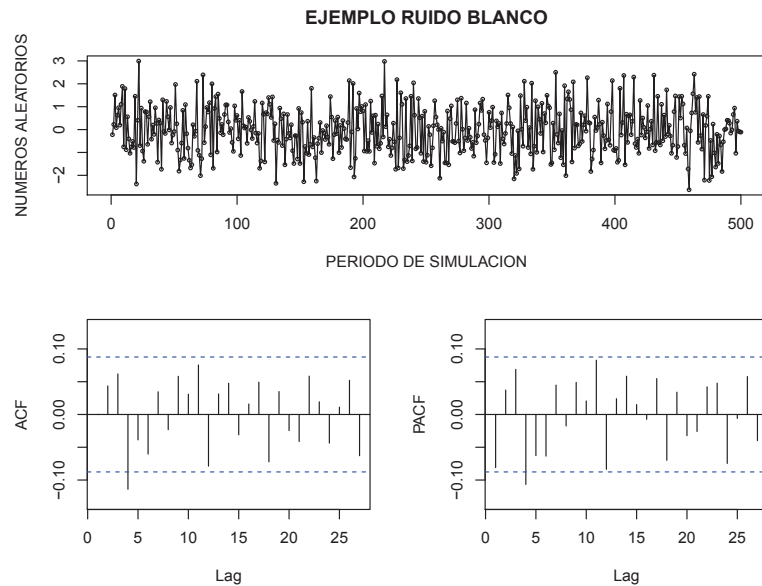


Figura 2.2: Simulación números aleatorios $N(0,1)$

Autocorrelación.- Según [Villavicencio Jhon, 2012][10], una serie temporal puede contener valores que no son independientes entre sí, sino que un valor

³ACF es el correlograma de la autocorrelación de los números aleatorios; y, PACF es el correlograma de la autocorrelación parcial de los números aleatorios; los números aleatorios representan a los residuos del modelo y fueron generados a través de una distribución Normal $N(0, \sigma^2)$

determinado depende de los valores anteriores. Existen dos formas de medir esta dependencia entre variables.

- **Función de Autocorrelación (ACF).**- Mide la correlación entre dos observaciones de una variable separadas por k períodos, se denota por la ecuación (2.18).

$$\rho_j = \text{corr}(X_j, X_{j-k}) = \frac{\text{cov}(X_j, X_{j-k})}{\sqrt{V(X_j)}\sqrt{V(X_{j-k})}} \quad (2.18)$$

- **Función de Autocorrelación Parcial (PACF).**- Mide la correlación entre dos observaciones de una variable separadas por k períodos cuando no se considera la dependencia creada por los retardos intermedios existentes entre ambas, se denotan por las ecuaciones (2.19) y (2.20).

$$\pi_j = \text{corr}(X_j, X_{j-k}/X_{j-1}X_{j-2} \dots X_{j-k+1}) \quad (2.19)$$

$$\pi_j = \frac{\text{cov}(X_j - \widehat{X}_j, X_{j-k} - \widehat{X}_{j-k})}{\sqrt{V(X_j - \widehat{X}_j)}\sqrt{V(X_{j-k} - \widehat{X}_{j-k})}} \quad (2.20)$$

Modelos Autoregresivos AR(p).- En los modelos autoregresivos, el valor actual de la serie X_t , puede explicarse en función de p valores pasados $X_{t-1}, X_{t-2}, \dots, X_{t-p}$ donde p es el número de rezagos necesarios para pronosticar un valor actual.

El modelo autoregresivo de orden p está dado por las ecuaciones (2.21), (2.22) y (2.23):

$$X_t = \phi_0 + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \epsilon_t \quad (2.21)$$

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) X_t = \epsilon_t \quad (2.22)$$

$$\phi_p(L) X_t = \epsilon_t \quad (2.23)$$

Donde:

ϵ_t = proceso de ruido blanco.

$\phi_0, \phi_1, \phi_2, \dots, \phi_p$ = parámetros del modelo.

$\theta_q(L)$ = modelo autoregresivo de orden (p).

Modelos de Medias Móviles MA(q).- Estos modelos suponen linealidad, el valor actual de la serie X_t está influenciado por los valores de la fuente externa.

El modelo de promedios móviles de orden q está dado por las ecuaciones (2.24), (2.25) y (2.26):

$$X_t = \theta_0 - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} - \epsilon_t \quad (2.24)$$

$$X_t = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \epsilon_t \quad (2.25)$$

$$X_t = \theta_q(L) \epsilon_t \quad (2.26)$$

Donde:

ϵ_t = proceso de ruido blanco.

$\theta_1, \theta_2, \dots, \theta_q$ = parámetros del modelo.

$\theta_q(L)$ = modelo media móvil de orden (q).

Modelos Autoregresivos Medias Móviles ARMA(p,q).- Según lo definido en [Capa Holger, 2007][13], un proceso estacionario de segundo orden se llama autoregresivo promedio móvil de orden p y q, con la notación ARMA(p,q), si puede representarse a través de la ecuación (2.27):

$$X_t - \sum_{i=1}^p a_i X_{t-i} = b_0 + \mu_t - \sum_{i=1}^q b_i \mu_{t-i} \quad (2.27)$$

donde los μ_t son variables aleatorias no correlacionadas dos a dos, centradas y de varianza constante σ^2 ; es decir, es un ruido blanco.

Si se consideran las v.a. X_t centradas, se tiene que $b_0 = 0$, por lo tanto, un proceso ARMA puede expresarse por la ecuación (2.28):

$$X_t - \sum_{i=1}^p a_i X_{t-i} = \mu_t - \sum_{i=1}^q b_i \mu_{t-i} \quad (2.28)$$

A continuación se mencionan dos consideraciones que pueden ocurrir en los modelos ARMA:

- Si el segundo sumatorio no existe, el proceso se dice autoregresivo de orden p (AR(p)); es decir, si $(X_t)_{t \in \mathbb{Z}}$ se puede representar por la ecuación (2.29):

$$X_t - \sum_{i=1}^p a_i X_{t-i} = b_0 + \mu_t \quad (2.29)$$

- Si el primer sumatorio no existe, el proceso se dice promedio móvil de orden q (MA(q)); es decir, si $(X_t)_{t \in \mathbb{Z}}$ se puede representar por la ecuación (2.30):

$$X_t = b_0 + \mu_t - \sum_{i=1}^q b_i \mu_{t-i} \quad (2.30)$$

Modelos ARIMA (Autoregressive Integrated Moving Average).- En [Cayuela Luis & Justel Ana, 2012][9], se define que, en el caso de las series no estacionarias, es necesario diferenciar la serie de tiempo original hasta obtener una serie estacionaria; a este procedimiento se lo denomina **proceso integrado**; con lo cual el modelo ARMA, se convierte en un modelo **ARIMA**.

En [Capa Holger, 2007][13], se define que un proceso no estacionario después de diferenciarlo d veces, se transforma en un proceso ARMA(p,q) y se denomina ARIMA(p,d,q).

Sea $(X_t)_{t \in \mathbb{Z}}$ de segundo orden y centrado, el proceso ARIMA(p,d,q), se puede representar por la ecuación (2.31):

$$\Phi(B)(1-B)^d X_t = \Theta(B)\mu_t, \quad t \in \mathbb{Z} \quad (2.31)$$

donde, $\Phi(Z)$ y $\Theta(Z)$ tienen sus raíces fuera del círculo unidad y (μ_t) es un ruido blanco de varianza σ^2 .

Proceso de Ajuste de los Modelos ARIMA.- En [Cayuela Luis & Justel Ana, 2012][9], se presenta la metodología de Box-Jenkins, que se utiliza para ajustar los modelos ARIMA, para lo cual se siguen los pasos descritos en la figura 2.3:

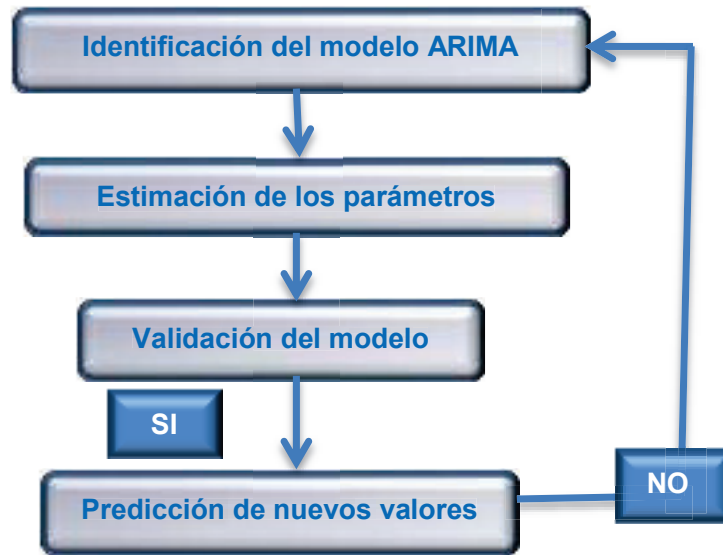


Figura 2.3: Metodología de Box-Jenkins

Modelos ARCH - GARCH.- Según lo definido en [Capa Holger, 2007][13], los modelos autoregresivos con heteroscedasticidad condicional ARCH y GARCH, permiten relacionar la varianza condicional (no constante) en función de información disponible en periodos anteriores; es decir, son diseñados para modelar y pronosticar varianzas condicionales.

También en [Capa Holger, 2007][13], se mencionan las siguientes definiciones de los modelos ARCH y GARCH.

- Un modelo ARCH(r) está definido por las ecuaciones (2.32) y (2.33):

$$X_t = \sqrt{h_t} \mu_t \quad (2.32)$$

$$h_t = \alpha_0 + \alpha_1 X_{t-1}^2 + \dots + \alpha_r X_{t-r}^2 \quad (2.33)$$

donde los (μ_t) son i.i.d $(0, 1)$ con $\alpha_0 > 0$ y $\alpha_i \geq 0$ para $i > 0$

En la práctica se supone que $\mu_t \rightarrow N(0, 1)$ o que siguen una distribución t-student.

- Un modelo GARCH(r,s) está definido por las ecuaciones (2.34) y (2.35):

$$X_t = \sqrt{h_t} \mu_t \quad (2.34)$$

$$h_t = \alpha_0 + \sum_{i=1}^r \alpha_i X_{t-i}^2 + \sum_{j=1}^s \beta_j h_{t-j} \quad (2.35)$$

donde los (μ_t) son i.i.d $(0, 1)$ con $\alpha_0 > 0$ y $\alpha_i \geq 0$ $\beta_j \geq 0$ para $i, j > 0$ y $\sum_{i=1}^r \alpha_i + \sum_{j=1}^s \beta_j < 1$

En la práctica se supone que $\mu_t \rightarrow N(0, 1)$ o que siguen una distribución t-student.

Las restricciones de no negatividad impuestas sobre los coeficientes en la definición son para asegurarse que la varianza no llegue a tomar un valor negativo. Sin embargo, con un poco de esfuerzo se puede llegar a encontrar condiciones menos restrictivas para estos coeficientes.

2.3.3. MODELOS DE DEPENDENCIA NO LINEAL: CÓPULAS

Introducción.- La teoría de cópulas se enfoca en modelar la estructura de dependencia entre las variables de riesgo que se están analizando, sin necesidad de partir de supuestos sobre sus distribuciones marginales, con lo cual se pretende evitar la sobrestimación o subestimación del valor en riesgo del portafolio, por lo tanto el concepto de Cópula es de gran ayuda para hacer frente a estos problemas. En [Torres & Olarte, 2009][7] también se define que el Valor en Riesgo en Cópulas, está dado por una función cópula, que permite resolver problemas de riesgo multivariado, es decir, “la función Cópula une en una distribución de probabilidad multivariada a una colección de funciones marginales univariadas. Se determina, de esta manera, la estructura de dependencia, tanto de la función de distribución conjunta del portafolio como de las marginales de cada activo riesgoso” (p. 117).

En [Bianco, Casparri & García, 2010][14], se menciona que el estudio del concepto estadístico de Cópula y su aplicación en finanzas es un fenómeno relativamente nuevo. La palabra Cópula apareció por primera vez en la literatura estadística en el año 1959, en el teorema desarrollado por Sklar⁴. Más específicamente, Cópulas son funciones que relacionan funciones de distribución

⁴En el año de 1959 Sklar dió respuesta al problema de determinar la relación entre la función de distribución de probabilidades multivariada definidas sobre el cubo unidad $[0, 1]^n$ y sus distribuciones marginales de menor dimensión, demostró que existe una función C , que denominó **cópula**, que establece la relación funcional entre la distribución conjunta y sus marginales unidimensionales.

multivariadas con sus correspondientes funciones marginales univariadas, funciones de distribución cuyos márgenes unidimensionales son uniformes. Este concepto de Cópula nos permite construir modelos que van más allá de los estándares en el análisis de dependencia entre variables estocásticas (p. 1).

Propiedades de la Función Cópula.- En [Torres & Olarte, 2009][7], se define que una función cópula d-dimensional es una función $C : [0, 1]^d \rightarrow [0, 1]$ que cumple las siguientes propiedades para cada: $\mu = (\mu_1, \mu_2, \dots, \mu_d)^T \in [0, 1]^d$

- I. Si $\mu_j = 0$ entonces $C(\mu_1, \mu_2, \dots, \mu_d) = 0$ para cada $j = 1 \dots d$
- II. $C(1, \dots, 1, \mu_j, 1, \dots, 1) = \mu_j$
- III. Para cada $v = (v_1, v_2, \dots, v_N)^T \in [0, 1]^d$, $v_j \leq \mu_j$, $V_c(\mu, v) \geq 0$

Con estas propiedades se puede decir que las cópulas son funciones univariadas, crecientes y no negativas.

Teorema de Sklar.- En [Cintas del Río, 2007][15], se menciona que el Teorema de Sklar establece la relación entre cópulas y funciones de distribución de variables aleatorias, con el fin de validar que las cópulas son funciones de distribución conjuntas, así como también verificar que se cumpla el recíproco de esta relación; es decir, que las funciones de distribución conjuntas se pueden reescribir en términos de las marginales y una única subcópula, que a su vez pueden extenderse a una cópula, en el caso que las distribuciones marginales y la distribución multivariada sean continuas la función cópula sería única. La definición del Teorema de Sklar, tomado de lo descrito en [Cintas del Río, 2007][15]:

Sea H una función de distribución n-dimensional con marginales F_1, \dots, F_n . Entonces existe una cópula n-dimensional C tal que $\forall X \in \overline{\mathfrak{X}}^n$

$$H(x_1, \dots, x_n) = C(F_1(x_1), \dots, F_n(x_n)) \quad (2.36)$$

Si F_1, \dots, F_n son todas continuas, entonces C es única, por tanto, está unívocamente determinada sobre $RanF_1 \times \dots \times RanF_n$.

Inversamente, si C es una cópula n -dimensional y F_1, \dots, F_n son funciones de distribución, entonces la función H definida anteriormente es una función de distribución n -dimensional con marginales F_1, \dots, F_n .

Por ejemplo para el caso bidimensional se reparte la probabilidad conjunta entre las marginales y una cópula, de forma que esta última solamente representa la asociación entre X e Y :

$$F(x, y) = C(F_1(x), F_2(y)) \quad (2.37)$$

Las cópulas separan el comportamiento marginal de F_1 y F_2 , contrario a lo que ocurre en la representación usual de probabilidades conjuntas a través de la función de distribución, por esta razón cópulas son denominadas *funciones de dependencia*.

Adicionalmente, en [Cintas del Río, 2007][15] se define el siguiente corolario: Sea F una función de distribución univariante, se denomina la inversa generalizada de F ; y, se denota por la ecuación (2.38):

$$F^{-1}(t) = \inf \{x \in \mathfrak{X} \mid F(x) \geq t\} \quad \forall t \in [0, 1] \quad (2.38)$$

Sea H una función de distribución n -dimensional con marginales continuas F_1, \dots, F_n y cópula C , entonces para cualquier $\mu \in [0, 1]^n$ se tiene la ecuación (2.39):

$$C(\mu_1, \dots, \mu_n) = H(F_1(\mu_1), \dots, F_n(\mu_n)) \quad (2.39)$$

La separación entre comportamientos marginales y dependencia conjunta explica la flexibilidad de las cópulas para establecer modelos de dependencia. El teorema de Sklar permite construir distribuciones bivariantes a través de la unión de una pareja de distribuciones marginales univariantes en una función que satisface la definición de cópula. Esto difiere de la manera tradicional de construir distribuciones multivariantes, que tienen la restricción de que las marginales son usualmente de mismo tipo, mientras que las cópulas admmiten marginales de diferentes tipos. Esta particularidad sugiere que cualquier problema de estimación debería descomponerse en dos etapas la primera relativa a las marginales y la segunda a la cópula misma.

Criterios para definir tipos de cópulas.- En [Becerra & Melo, 2008][16] se presenta un resumen de los criterios bajo los cuales se categoriza a la familia de cópulas:

- **Primer Criterio:** Cópulas límite o Cópula fundamentales, se encuentran asociadas con los casos extremos de dependencia: comonotonicidad, contramonotonicidad e independencia.
- **Segundo Criterio:** Asociado a la forma funcional de la cópula, y son de dos tipos, “cópulas explícitas, aquellas que pueden ser expresadas a través de una forma funcional cerrada, o implícitas las cuales son derivadas de funciones de distribución multivariadas conocidas, aunque sus formas funcionales no son simples o cerradas” (p. 20).
- **Tercer Criterio:** “Depende directamente de las características particulares de las cópulas” (p. 20). Bajo este criterio, es posible identificar cuatro familias de cópulas: Elípticas, Arquimedianas, Valor Extremo y Arquimax.

Familias de Cópulas.- Además de los criterios para seleccionar una cópula, [Becerra & Melo, 2008][16] mencionan que, se debe considerar los métodos de estimación de los parámetros asociados a una cópula, éstos son los siguientes: estimación no paramétrica, estimación a través de las correlaciones de rango que utiliza el método de momentos y finalmente, se tiene el método de máxima verosimilitud que se basa en la maximización de la función logarítmica de verosimilitud.

Los modelos de medición de riesgo que realizan supuestos más realistas sobre las funciones de distribución marginales de las series, si bien puede ser más costosos en términos computacionales, cuantifican de mejor manera el riesgo del portafolio. En este sentido, los modelos derivados de la cópula ofrecen una estructura analítica flexible que resulta apropiada para la medición de riesgo (p. 78).

En función de los criterios antes mencionados, se han generado cuatro familias de Cópulas:

- I. **Cópulas Elípticas.-** Están asociadas a variables aleatorias cuya función de distribución multivariada es de la forma $f(x'x)$ (significa la multiplicación de la matriz o vector de la variable aleatoria transpuesta por la matriz o vector de la variable aleatoria), es decir sus curvas de nivel serán elípticas. Las más importantes en esta familia son la cópula normal o

gaussiana y la cópula t de student, las cuales se derivan de las funciones de distribución multivariada que poseen estos mismos nombres (p.20).

- **Cópula Normal.-** En [Denuit & Dhaene, 2005][17], se menciona que la cópula Normal (o gaussiana) describe la estructura de dependencia inducida por la distribución normal bivariada, se la puede definir como la cópula resultante de la descomposición de Sklar, aplicada a la función de distribución conjunta de una cópula aleatoria (X_1, X_2) que siguen una normal $N(0, 1)$ con covarianza α . La cópula normal, está dada por la ecuación (2.40):

$$C_\alpha(\mu_1, \mu_2) = H_\alpha(\Phi_{-1}(\mu_1), \Phi_{-1}(\mu_2)), \quad \alpha \in (-1, 1) \quad (2.40)$$

donde Φ es la función de densidad de la distribución univariada $N(0, 1)$ y H_α es la función de densidad de la normal estándar bivariada con covarianza α :

$$C_\alpha(\mu_1, \mu_2) = \frac{1}{2\pi\sqrt{1-\alpha^2}} \int_{-\infty}^{\Phi^{-1}(\mu_1)} \int_{-\infty}^{\Phi^{-1}(\mu_2)} \exp\left(\frac{-(\xi_1^2 - 2\alpha\xi_1\xi_2 + \xi_2^2)}{2(1-\alpha^2)}\right) d\xi_1 d\xi_2 \quad (2.41)$$

donde $\xi_i = \Phi^{-1}(\mu_i)$, $i = 1, 2$, tal que la función de densidad de probabilidad de la cópula Gaussiana está dada por la ecuación (2.42):

$$C_\alpha(\mu_1, \mu_2) = \frac{1}{\sqrt{1-\alpha^2}} \exp\left(\frac{-(\xi_1^2 - 2\alpha\xi_1\xi_2 + \xi_2^2)}{2(1-\alpha^2)}\right) \exp\left(\frac{\xi_1^2 + \xi_2^2}{2}\right) \quad (2.42)$$

- **Cópula t.-** En [Denuit & Dhaene, 2005][17], se menciona que la cópula de Student se obtiene de la distribución de Student bivariada. La función de densidad de la distribución univariada de Student con m grados de libertad, se denota por la ecuación (2.43):

$$t_m(x) = \int_{-\infty}^x \frac{\Gamma\left(\frac{m+1}{2}\right)}{\sqrt{m\pi} \Gamma\left(\frac{m}{2}\right)} \left(1 + \frac{\xi^2}{m}\right)^{-\frac{m+1}{2}} d\xi \quad (2.43)$$

La función de densidad conjunta de la distribución bivariada de Student, con $0 < \alpha < 1$ se denota por la ecuación (2.44):

$$t_{m,\alpha}(x) =$$

$$\int_{-\infty}^{x_1} \int_{-\infty}^{x_2} \frac{1}{2\pi \sqrt{1-\alpha^2}} \left(1 + \frac{\xi_1^2 + \xi_2^2 - 2\alpha\xi_1\xi_2}{m(1-\alpha^2)}\right)^{-\frac{m+2}{2}} d\xi_1 d\xi_2 \quad (2.44)$$

La cópula bivariada de Student está definida por la ecuación (2.45):

$$C_{m,\alpha}(\mu_1, \mu_2) = t_{m,\alpha}(t_m^{-1}(\mu_1), t_m^{-1}(\mu_2)) \quad (2.45)$$

$$= \int_{-\infty}^{t_m^{-1}(\mu_1)} \int_{-\infty}^{t_m^{-1}(\mu_2)} \frac{1}{2\pi \sqrt{1-\alpha^2}} \left(1 + \frac{\xi_1^2 + \xi_2^2 - 2\alpha\xi_1\xi_2}{m(1-\alpha^2)}\right)^{-\frac{m+2}{2}} d\xi_1 d\xi_2$$

Cuando el número m de grados de libertad tiende a $+\infty$ entonces la cópula de Student converge a la cópula Normal. Para un número limitado de grados de libertad las dos cópulas tienen formas diferentes. La densidad de la cópula de Student está dada por la ecuación (2.46):

$$C_{m,\alpha}(\mu) = \alpha^{-1/2} \frac{\Gamma(\frac{m+2}{2}) \Gamma(\frac{m}{2})}{(\Gamma(\frac{m+1}{2}))^2} \left(1 + \frac{\xi_1^2 + \xi_2^2 - 2\alpha\xi_1\xi_2}{m(1-\alpha^2)}\right)^{-\frac{m+2}{2}} * \left(1 + \frac{\xi_1}{m}\right)^{-\frac{m+2}{2}} \left(1 + \frac{\xi_2}{m}\right)^{-\frac{m+2}{2}} \quad (2.46)$$

donde $\xi_1 = t_m^{-1}(\mu_1)$ y $\xi_2 = t_m^{-1}(\mu_2)$. La familia de cópulas Student es amplia en el sentido de que:

$$\lim_{\alpha \rightarrow -1} C_{m,\alpha} = C_L, \quad \lim_{\alpha \rightarrow 1} C_{m,\alpha} = C_U, \text{ paracualquier } m \quad (2.47)$$

Donde C_L y C_U son las cotas inferior y superior, respectivamente, de las cópulas t de Student. Sin embargo, $C_{m,0} \neq C_I$ para m finito.

En la tabla 2.1, se presenta un resumen de las medidas de dependencia de las cópulas elípticas:

Cópula	τ de Kendall	S de Spearman	$\lambda_\mu = \lambda_t$
Gaussiana	$\frac{2}{\pi} \arcsin(\rho_{ij})$	$\frac{6}{\pi} \arcsin(\frac{1}{2}\rho_{ij})$	0
t de Student	$\frac{2}{\pi} \arcsin(\rho_{ij})$	-	$2t_{v+1}\left(-\sqrt{\frac{(v+1)(1-\rho)}{1+\rho}}\right)$

Tabla 2.1: Medidas de dependencia para las cópulas Elípticas

- II. **Cópulas Arquimedianas.**- “Conforman una de las familias más representativas y estudiadas en el ámbito teórico y aplicado. En general, su popularidad se encuentra asociada a su sencilla definición, la cual ha permitido

construir un numeroso grupo de funciones que pertenecen a esta familia” (p. 23), según [Nelsen, 2006] citado en [Becerra & Melo, 2008][16], entre las cuales tenemos las siguientes:

- **Cópula Clayton.-** En [Denuit & Dhaene, 2005][17], se menciona que la cópula Clayton se suele atribuir a Clayton (1978), pero en realidad su origen se remonta al menos a Kimeldorf y Sampson (1975). Se define para $\mu \in [0, 1]^2$ como:

$$C_{\alpha}(\mu_1, \mu_2) = (\mu_1^{-\alpha} + \mu_2^{-\alpha} - 1)^{-\frac{1}{\alpha}}, \quad \alpha > 0 \quad (2.48)$$

El primer estudio sistemático de esta clase de distribuciones fue publicado por Cook y Johnson (1981), que interpretan el parámetro α como una medida de la fuerza de la dependencia entre los μ_i . Se puede verificar que la estructura de dependencia se aproxima al máximo cuando α se incrementa hacia $+\infty$

$$\lim_{\alpha \rightarrow +\infty} C_{\alpha}(\mu_1, \mu_2) = \min\{\mu_1, \mu_2\} = C_U(\mu) \quad (2.49)$$

Donde $C_U(\mu)$ es la cota superior, de la cópula de Clayton. Por otra parte, la independencia se obtiene cuando α tiende a 0; es decir, esta cópula presenta dependencia únicamente en el extremo de la cola inferior.

$$\lim_{\alpha \rightarrow 0} C_{\alpha}(\mu_1, \mu_2) = \mu_1 \mu_2 = C_I(\mu) \quad (2.50)$$

Donde $C_I(\mu)$ es la cópula de Clayton donde se alcanza la independencia, justamente cuando α tiende a 0. Existe un caso particular de esta familia de cópulas que es la cópula de Clayton Generalizada, la cual presenta dependencia en los extremos de ambas colas. El generador de esta cópula es $\phi(t) = \theta^{-\delta} (t^{-\theta} - 1)^{\delta}$, donde $\theta > 0$ y $\delta \geq 1$. Para el caso bivariado, la cópula Clayton generalizada se denota por la ecuación (2.51):

$$C^{CG}(\mu_1, \mu_2) = \left\{ \left[(\mu_1^{-\theta} - 1)^{\delta} + (\mu_2^{-\theta} - 1)^{\delta} \right]^{1/\delta} + 1 \right\}^{-\frac{1}{\theta}} \quad (2.51)$$

- **Cópula Frank.-** En [Denuit & Dhaene, 2005][17], se menciona que la cópula de Frank apareció por primera vez en Frank(1979) como una solución al problema de la ecuación funcional. Esta familia de

cóputas fue estudiada por Genest(1987). La cóputa de Frank está dada por la ecuación (2.52) cuando $\mu \in [0, 1]^2$ y para $\alpha \neq 0$:

$$C_{\alpha}(\mu_1, \mu_2) = -\frac{1}{\alpha} \ln \left(1 + \frac{(\exp(-\alpha\mu_1) - 1)(\exp(-\alpha\mu_2) - 1)}{\exp(-\alpha) - 1} \right) \quad (2.52)$$

Es fácil comprobar que los casos de los límites de C_{α} incluyen C_L , C_U y C_I :

$$\lim_{\alpha \rightarrow -\infty} C_{\alpha} = C_L, \quad \lim_{\alpha \rightarrow +\infty} C_{\alpha} = C_U, \quad \lim_{\alpha \rightarrow 0} C_{\alpha} = C_I \quad (2.53)$$

Por lo tanto, se dice que **la familia de cóputas de Frank es completa**; es decir, **no presenta dependencia en ninguna de las dos colas** no presenta dependencia en ninguna de las dos colas.

- **Cóputa Gumbel.**- En [Cintas del Río, 2007][15] se presenta la siguiente definición de esta cóputa: Sea $\varphi(t) = (-\ln t)^{\theta}$ $\theta \geq 1$. Dado que $\varphi(t)$ es continua, $\varphi(1) = 0$, $\varphi'(t) = -\theta(-\ln t)^{\theta-1} \frac{1}{t}$, por tanto φ es estrictamente decreciente en $[0, \infty]$. Además se tiene que $\varphi''(t) \geq 0$ en $[0, 1]$, por lo que φ es convexa. Como $\varphi(0) = \infty$, φ es un generador estricto. La expresión general en el caso bidimensional de esta familia está dada por las ecuaciones (2.54) y (2.55):

$$C_{\theta}(\mu, \nu) = \varphi^{-1}(\varphi(\mu) + \varphi(\nu)) \quad (2.54)$$

$$C_{\theta}(\mu, \nu) = \exp\left(-\left[(-\ln\mu)^{\theta} + (-\ln\nu)^{\theta}\right]^{1/\theta}\right) \quad (2.55)$$

Además, $C_1 = \Pi$ y $\lim_{\theta \rightarrow \infty} C_{\theta} = M$, considerar que $\Pi(\mu, \nu) = \mu\nu$ y $M(\mu, \nu) = \min(\mu, \nu)$. La dependencia en las colas de esta cóputa, se denota por las ecuaciones (2.56) y (2.57):

$$\varphi^{-1}(s) = \exp\left(-s^{1/\theta}\right) \quad y \quad (2.56)$$

$$\varphi^{-1}'(s) = \frac{-\exp\left(-s^{1/\theta}\right)}{\theta} \quad (2.57)$$

Por lo tanto, esta familia de cóputas **presenta dependencia únicamente en el extremo de la cola superior**.

En la tabla 2.2, se presenta un resumen del coeficiente τ de Kendall y los coeficientes de dependencia en las colas para las cóputas de Arquímedes:

Cópula	τ de Kendall	λ_μ	λ_t
Clayton	$\frac{\theta}{\theta+2}$	0	$2^{-1/\theta}$
Frank	$1 - \frac{4}{\theta} \left[1 - \frac{1}{\theta} \int_0^\theta \frac{t}{\exp(t)-1} dt \right]$	0	0
Gumbel	$1 - \frac{1}{\theta}$	$2 - 2^{1/\theta}$	0
Clayton Generalizada	$\frac{(2+\theta)\delta-2}{(2+\theta)\delta}$	$2 - 2^{1/\delta}$	$2^{-1/(\theta\delta)}$

Tabla 2.2: Medidas de dependencia para las cópulas de Arquímedes

III. **Cópula de Valor Extremo.**- En [Bianco, Casparri, & García, 2010][14], se define que las cópulas de Valor Extremo son derivadas de la estructura de dependencia de la distribución generalizada de valores extremos multivariada, la expresión de esta cópula se denota por la ecuación (2.58):

$$C(\mu, \nu) = \exp \left\{ \ln(\mu, \nu) A \left(\frac{\ln \nu}{\ln(\mu, \nu)} \right) \right\} \quad (2.58)$$

donde $A : [0, 1] \rightarrow \left[\frac{1}{2}, 1 \right]$ (función de dependencia) es convexa y verifica :

$$\max \{t, 1 - t\} \leq A(t) \leq 1 \quad \forall t \in [0, 1] \quad (2.59)$$

En general una cópula de valor satisface la ecuación (2.60):

$$C(\mu_1^t, \dots, \mu_d^t) = [C(\mu_1, \dots, \mu_d)]^t \quad \forall t > 0 \quad (2.60)$$

IV. **Cópula Arquimax.**- En [Becerra & Melo, 2008][16] se presenta que la cópula de Arquimax surge de la combinación entre las cópulas de valor extremo y las cópulas de Arquímedes, se denota por la ecuación (2.61):

$$C(\mu_1, \mu_2) = \phi^{-1} \left[(\phi(\mu_1) + \phi(\mu_2)) A \left(\frac{\phi(\mu_1)}{\phi(\mu_1) + \phi(\mu_2)} \right) \right] \quad (2.61)$$

Donde $A(t)$ es una función de dependencia similar a la definida para las cópulas de valor extremo y $\phi(t)$ es el generador de las cópulas de Arquímedes.

Consecuentemente, tanto las cópulas de Arquímedes como las de valor extremo pueden ser consideradas como casos particulares de la familia Arquimax; por lo tanto, si $A(t) = 1$ la familia Arquimax toma la forma de una cópula de Arquímedes, mientras que las cópulas de valor extremo se obtienen cuando $\phi(t) = -\log(t)$.

Capítulo 3

MODELO PROPUESTO PARA MEDIR EL RETIRO EN RIESGO

3.1. INFORMACIÓN ANALIZADA

La población de estudio está constituida por un gran volumen de información, que involucra las salidas de depósitos que han ocurrido al menos desde el año 2001¹ en todas las Entidades Financieras; por lo tanto, como esta investigación es de carácter inductivo; es decir, pretende ir de lo particular a lo general, se enfocará en inferir la metodología que presente el mejor ajuste al comportamiento real de los datos, a partir de una muestra tomada en una entidad financiera.

La periodicidad de la información es diaria, para una ventana temporal histórica de 3 meses; y, un mes adicional para validar el modelo y desarrollar una metodología de gestión del retiro en riesgo.

Las variables que son necesarias para esta investigación son: saldo, crédito y débito; de cada una de las fuentes de fondeo que son descritas a continuación:

- Cuenta contable 2101: Depósitos a la vista (neta de 210120 y 210135)
- Cuenta contable 2103: Depósitos a plazo
- Cuenta contable 210135: Depósitos de ahorro

¹Fecha en la que el Ecuador adoptó el dólar norteamericano como moneda corriente para transacciones internas de su economía y para registro de sus operaciones.

3.1.1. SOFTWARE ESTADÍSTICO Y LIBRERÍAS

El análisis de la información constituye una parte fundamental en el desarrollo de esta investigación; en este sentido, a través de la experimentación artificial sobre la base de modelos estadísticos y con la ayuda del paquete estadístico **R** (software libre), se confirmarán o rechazarán las hipótesis del modelo. Las librerías que se utilizarán son:

Librerías para funciones generales

```
> library(MASS)
> library(fBasics)
> library(ADGofTest)
> library(xtable)
> library(stats)
> library(stats4)
```

Librerías para series de tiempo

```
> library(quadprog)
> library(zoo)
> library(tseries)
> library(fracdiff)
> library(nnet)
> library(car)
> library(urca)
> library(fGarch)
> library(TSA)
> library(forecast)
```

Librerías para cópulas

```
> library(mvtnorm)
> library(scatterplot3d)
> library(sn)
> library(mnormt)
```

```

> library(pspline)
> library(copula)
> library(copulaedas)
> library(CopulaRegression)
> library(copBasic)

```

3.2. REVISIÓN DEL MÉTODO ACTUAL: LIQUIDEZ ESTRUCTURAL

Conforme lo descrito en la metodología de la Superintendencia de Bancos y Seguros², se presenta el cálculo del requerimiento de liquidez, efectuado a través de los indicadores de liquidez de primera y segunda línea.

- **Cálculo de la volatilidad de cada fuente de fondeo.**- Se seleccionan los saldos de las cuentas contables: 2101, 2103 y 210135; para una ventana temporal de 90 días.
- **Cálculo de la tasa de variación logarítmica.**- Para cada fuente de fondeo, se calcula la variación logarítmica del saldo del día t+30 versus el día t:

$$\Delta S_{corriente} = \frac{S_{corriente}(t + 30)}{S_{corriente}(t)} \quad (3.1)$$

$$\Delta S_{plazo} = \frac{S_{plazo}(t + 30)}{S_{plazo}(t)} \quad (3.2)$$

$$\Delta S_{ahorros} = \frac{S_{ahorros}(t + 30)}{S_{ahorros}(t)} \quad (3.3)$$

Para $t = 1, 2, 3, 4, 5, \dots, 60$ días de cálculo

```

> logsaldo.corriente<-log(BASEMLE.corriente2/BASEMLE.corriente1)
> logsaldo.ahorros <- log(BASEMLE.plazo2/BASEMLE.plazo1)
> logsaldo.plazo <- log(BASEMLE.ahorros2/BASEMLE.ahorros1)
> log.saldos <- matrix(c(logsaldo.corriente,
+                       logsaldo.ahorros,logsaldo.plazo),
+                       nrow=60,ncol=3,byrow=FALSE)

```

²Instructivo para la aplicación del Concepto del Valor en Riesgo (VaR) para la estimación de la Liquidez estructural requerida por las Instituciones Financieras, Octubre 2004.

- **Cálculo de la desviación estándar de cada fuente de fondeo.**- Posteriormente, se calcula la desviación estándar, para cada vector ΔS .

```
> sd.saldos<-apply(log.saldos,2,sd)
```

	corriente	plazo	ahorros
desv.est.	0.0535	0.0443	0.1016

Tabla 3.1: Desviación estándar de los depósitos analizados

3.2.1. MÉTODO DE LA VOLATILIDAD PROMEDIO PONDERADA

- Se calcula el peso total, dado por la suma de los saldos de las fuentes de fondeo: corriente, plazo, ahorros; registrados en el día 90 de la ventana temporal.

$$Saldo\ total = \sum_f Saldo_f(t = 90) \quad (3.4)$$

Para f = corriente, plazo, ahorros

```
> peso.total<-sum(BASEMLE[90,c(1,4,7)])
```

- Se calcula el peso ponderado de cada fuente de fondeo, dividiendo los saldos de las fuentes de fondeo: corriente, plazo, ahorros; registrados en el día 90 de la ventana temporal, para el saldo total.

$$Peso\ ponderado = \left(\frac{Saldo_{corriente}(t=90)}{Saldo\ total} \quad \frac{Saldo_{plazo}(t=90)}{Saldo\ total} \quad \frac{Saldo_{ahorros}(t=90)}{Saldo\ total} \right) \quad (3.5)$$

```
> peso.pond<-round(BASEMLE[90,c(1,4,7)]/peso.total,4)
```

- La **volatilidad general**, se determina a través de la suma producto del peso ponderado por la desviación estándar.

$$Volatilidad\ general = \sum_f Peso.ponderado_f * Desv.est._f \quad (3.6)$$

Para f = corriente, plazo, ahorros

```
> volat.general<-round(sum(peso.pond*sd.saldos),4)
```

- El indicador de primera línea es equivalente a 2 veces la volatilidad general no diversificada.

```
> IEL1<-2*volat.general
```

- El indicador de segunda línea es equivalente a 2.5 veces la volatilidad general no diversificada.

```
> IEL2<-2.5*volat.general
```

3.2.2. MÉTODO DEL VALOR EN RIESGO

- Se calcula la matriz de volatilidad individual, multiplicando los saldos de las fuentes de fondeo: corriente, plazo, ahorros; registrados en el día 90 de la ventana temporal, por su respectiva desviación estándar.

$$Volat. indiv. = \begin{pmatrix} Saldo_{corriente}(t = 90) * Desv.est_{corriente} \\ Saldo_{plazo}(t = 90) * Desv.est_{plazo} \\ Saldo_{ahorros}(t = 90) * Desv.est_{ahorros} \end{pmatrix} \quad (3.7)$$

```
> volat.indiv <- BASEMLE[90,c(1,4,7)]*sd.saldos
> mvolat.indiv <- matrix(c(volat.indiv$Saldo_2101,
+                          volat.indiv$Saldo_2103,
+                          volat.indiv$Saldo_210135),
+                          nrow=1,ncol=3)
```

- Se calcula la matriz de correlación del logaritmo de la variación de saldos $\left(\frac{t+30}{t}\right)$, a través del método de “**pearson**”

```
> mcorrelacion<-cor(log.saldos,method="pearson")
```

- Se multiplica la matriz de volatilidad individual por la matriz de correlación.

```
> M1<-mvolat.indiv%%mcorrelacion
> M3<-t(mvolat.indiv)
> M2<-M1%%M3
> VaRG<-sqrt(M2)
```


- Se calcula la raíz cuadrada del producto matricial calculado en el ítem anterior, este resultado constituye la estimación del **VaR general**.

```
> VaRG<-sqrt(M2)
```

- La **volatilidad general diversificada**, se determina a través del cociente entre el **VaR general** sobre el peso total.

```
> sigmaVaRG<-round(VaRG/peso.total,4)
```

- El indicador de primera línea y segunda línea es equivalente a 2 y 2.5 veces la volatilidad general diversificada, respectivamente.

```
> IEL3<-2*sigmaVaRG
```

```
> IEL4<-2.5*sigmaVaRG
```

3.2.3. RESULTADOS: INDICADORES DE LIQUIDEZ

En la tabla 3.2, se presentan los resultados estimados por el método de la volatilidad promedio ponderada y por el método del valor en riesgo.

Tipo de indicador	Valor (%)
Primera línea volatilidad general	0.1262
Segunda línea volatilidad general	0.1578
Primera línea valor en riesgo	0.1090
Segunda línea valor en riesgo	0.1363

Tabla 3.2: Indicadores de liquidez estructural

3.3. ESQUEMA DEL MODELO PROPUESTO

El modelo propuesto para estimar el “**riesgo de liquidez**” por “**retiro de depósitos**”, denominado “**retiro en riesgo**”, contempla el desarrollo de las siguientes etapas:

- Consolidación de la base de datos y definición del parámetro de medida.
- Modelo de autocorrelación para la media y varianza condicional, ARIMA - GARCH.

- Modelo de correlación no lineal: cópulas.
- Estimación del parámetro de cuantificación del riesgo de liquidez: retiro de depósitos que se estima ocurrir durante un horizonte de tiempo determinado.
- Pruebas retrospectivas de calibración.

A continuación en las figuras: 3.1, 3.2, 3.3, 3.4 y 3.5, se presenta un esquema que define el proceso de estimación del retiro en riesgo para un horizonte temporal de 30 días.

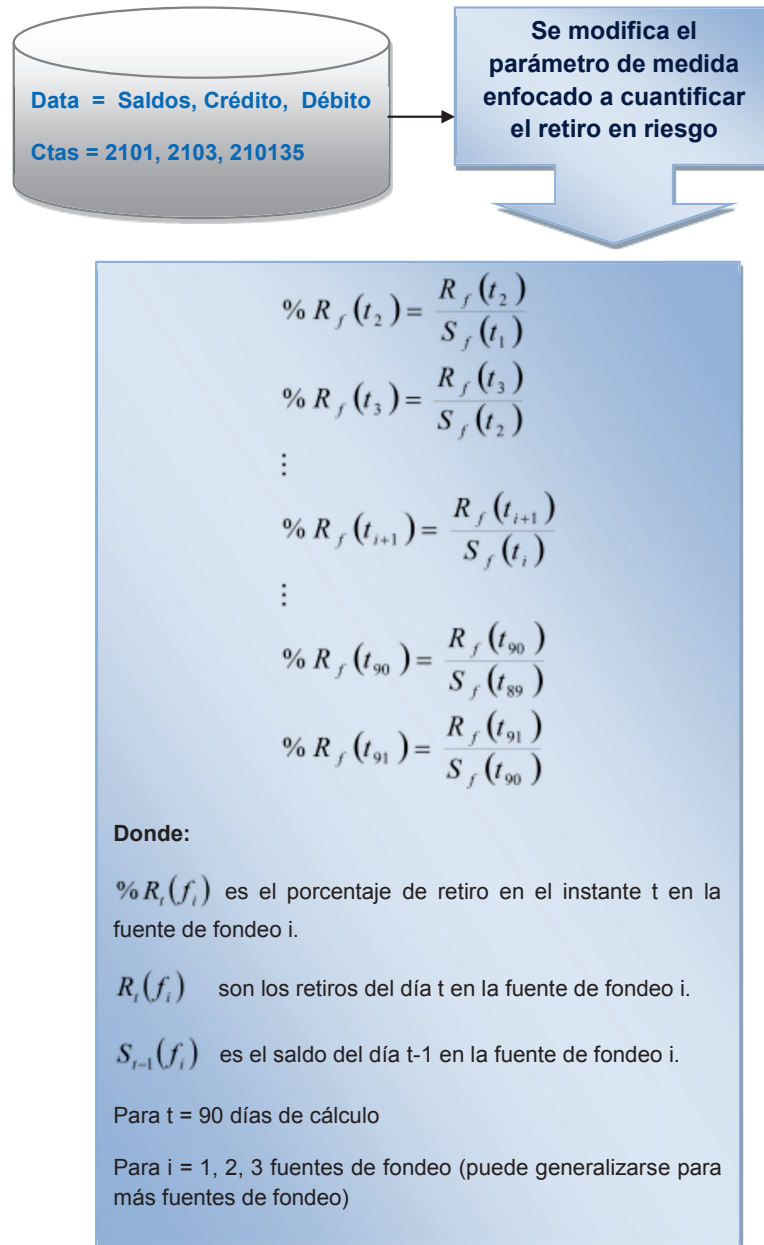


Figura 3.1: Base de datos y definición de parámetro de medida

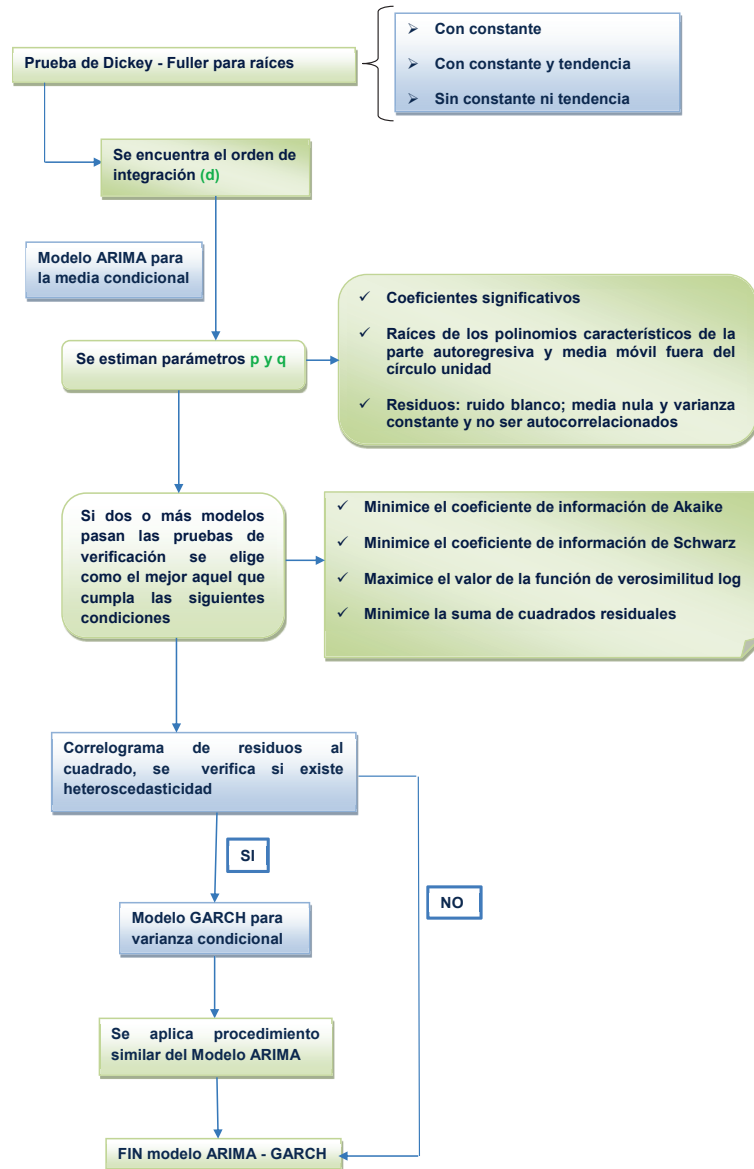


Figura 3.2: Modelo de autocorrelación: arima - garch

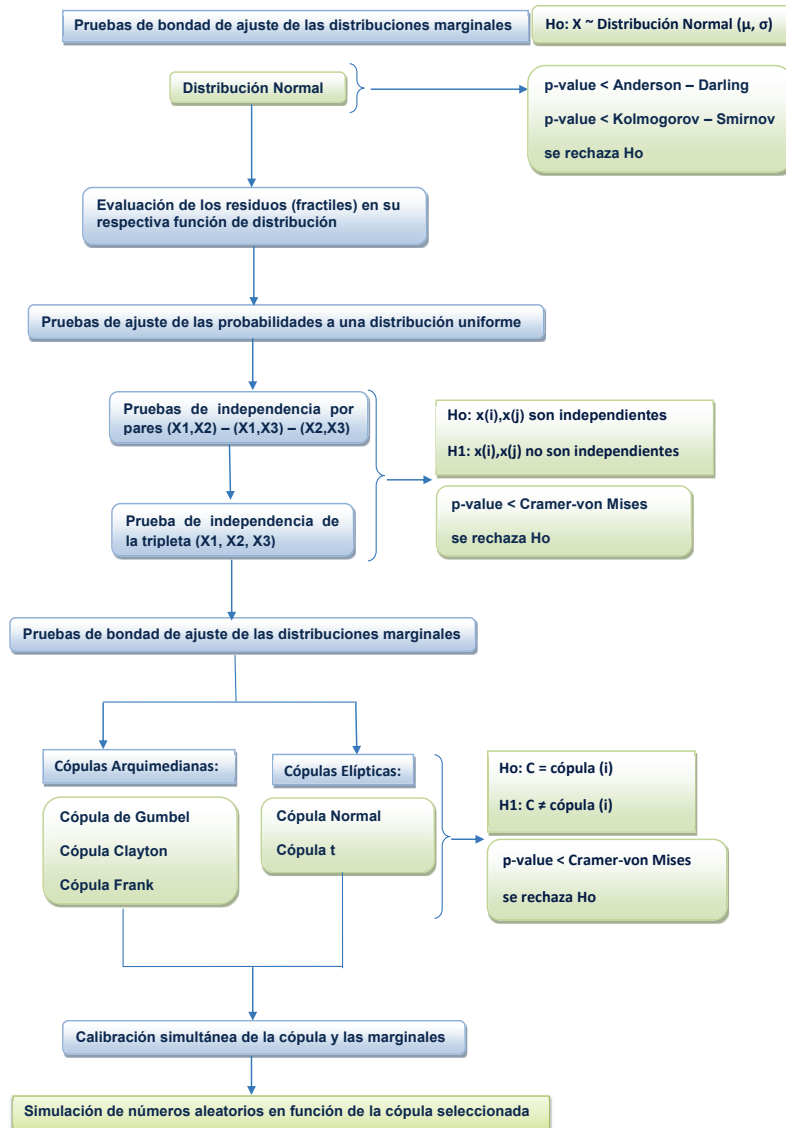


Figura 3.3: Modelo de correlación no lineal: Cóputas

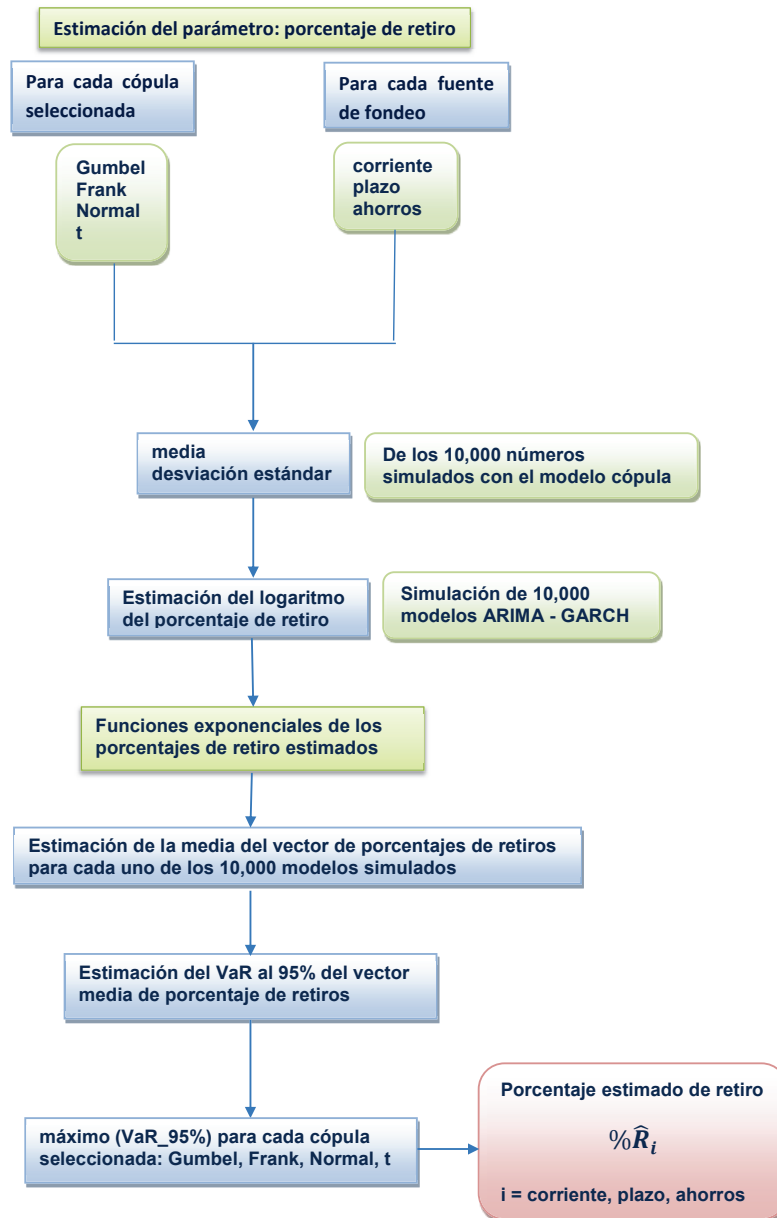


Figura 3.4: Estimación del valor de retiro en riesgo

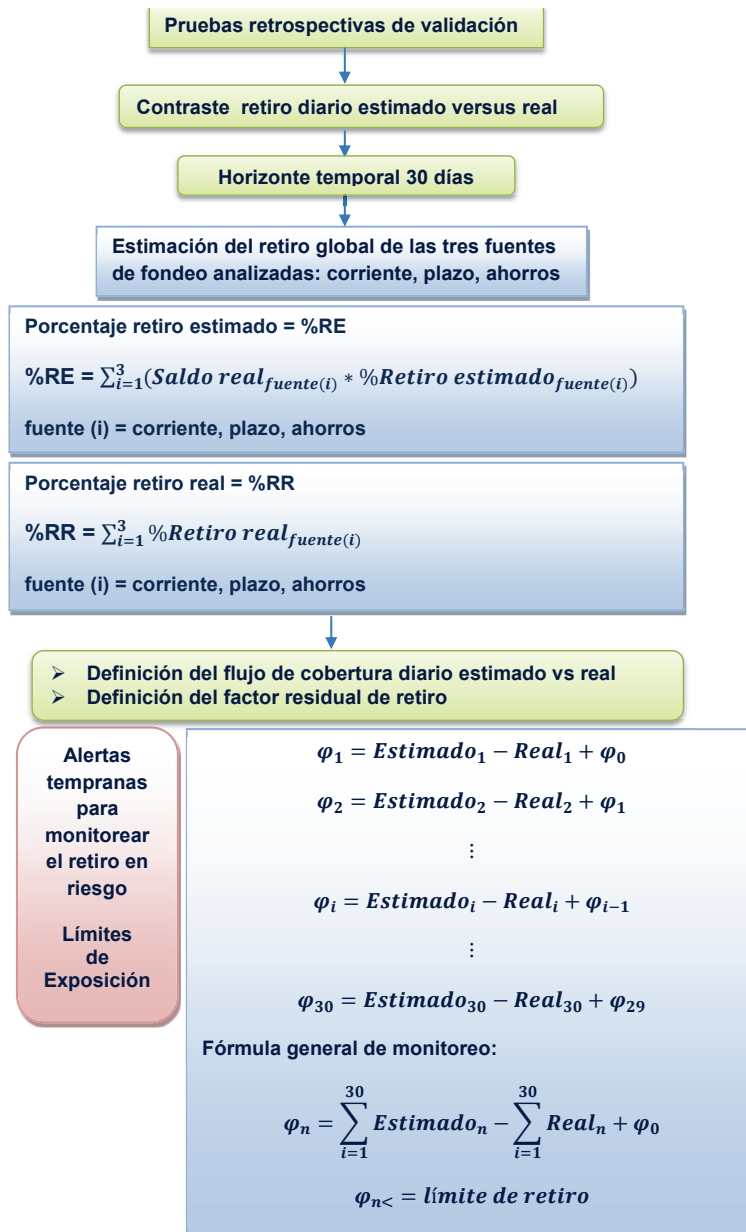


Figura 3.5: Pruebas retrospectivas de calibración

3.4. DEFINICIÓN DEL PARÁMETRO DE MEDIDA

Para cada fuente de fondeo analizada y para los últimos 91 días incluido el día de cálculo, se calcula el porcentaje de retiro con respecto al saldo final del día anterior; la matriz de datos resultante es la siguiente:

$$\left(\begin{array}{ccc} \%R_{corriente}(t_2) = \frac{R_{corriente}(t_2)}{S_{corriente}(t_1)} & \%R_{plazo}(t_2) = \frac{R_{plazo}(t_2)}{S_{plazo}(t_1)} & \%R_{ahorros}(t_2) = \frac{R_{ahorros}(t_2)}{S_{ahorros}(t_1)} \\ \%R_{corriente}(t_3) = \frac{R_{corriente}(t_3)}{S_{corriente}(t_2)} & \%R_{plazo}(t_3) = \frac{R_{plazo}(t_3)}{S_{plazo}(t_2)} & \%R_{ahorros}(t_3) = \frac{R_{ahorros}(t_3)}{S_{ahorros}(t_2)} \\ \%R_{corriente}(t_4) = \frac{R_{corriente}(t_4)}{S_{corriente}(t_3)} & \%R_{plazo}(t_4) = \frac{R_{plazo}(t_4)}{S_{plazo}(t_3)} & \%R_{ahorros}(t_4) = \frac{R_{ahorros}(t_4)}{S_{ahorros}(t_3)} \\ \vdots & \vdots & \vdots \\ \%R_{corriente}(t_{i+1}) = \frac{R_{corriente}(t_{i+1})}{S_{corriente}(t_i)} & \%R_{plazo}(t_{i+1}) = \frac{R_{plazo}(t_{i+1})}{S_{plazo}(t_i)} & \%R_{ahorros}(t_{i+1}) = \frac{R_{ahorros}(t_{i+1})}{S_{ahorros}(t_i)} \\ \vdots & \vdots & \vdots \\ \%R_{corriente}(t_{90}) = \frac{R_{corriente}(t_{90})}{S_{corriente}(t_{89})} & \%R_{plazo}(t_{90}) = \frac{R_{plazo}(t_{90})}{S_{plazo}(t_{89})} & \%R_{ahorros}(t_{90}) = \frac{R_{ahorros}(t_{90})}{S_{ahorros}(t_{89})} \\ \%R_{corriente}(t_{91}) = \frac{R_{corriente}(t_{91})}{S_{corriente}(t_{90})} & \%R_{plazo}(t_{91}) = \frac{R_{plazo}(t_{91})}{S_{plazo}(t_{90})} & \%R_{ahorros}(t_{91}) = \frac{R_{ahorros}(t_{91})}{S_{ahorros}(t_{90})} \end{array} \right)$$

Donde:

$\%R_f$ → porcentaje de retiro en el día t en la fuente de fondeo f = corriente, plazo, ahorros

R_f → retiro en el día t en la fuente de fondeo f = corriente, plazo, ahorros

S_f → saldo en el día t-1 en la fuente de fondeo f = corriente, plazo, ahorros

Para $t = 1, 2, 3, 4, 5, \dots$, 91 días de cálculo

3.5. SELECCIÓN Y CREACIÓN DE VARIABLES

De la base total de obligaciones, se seleccionan las variables: saldos, captaciones y retiros de las fuentes que serán analizadas.

```
> BASETOTAL<-read.table("BASEMLE.txt", header=TRUE, sep="\\t",
+ dec=".", as.is=FALSE, na.strings="NA", skip=0, fill=TRUE,
+ check.names=TRUE, strip.white=FALSE, blank.lines.skip= TRUE,
+ comment.char="")
```


Posteriormente, se crean las variables que ingresarán al modelo, a través de la definición del parámetro de medida, dada por la variación diaria del vector de retiros en el día (t) dividido para el saldo del día (t-1) para cada fuente de fondeo.

```
> corriente<-BASEML[-1,3]/BASEML[-91,1]
> plazo<-BASEML[-1,6]/BASEML[-91,4]
> ahorros<-BASEML[-1,9]/BASEML[-91,7]
```

En la tabla 3.3 se detallan estadísticas descriptivas del nuevo parámetro de medida que será analizado en cada fuente de fondeo:

Estad.	Corriente (%)	A Plazo (%)	Ahorros (%)
min	9.55	0.37	2.91
max	33.02	7.72	33.01
media	16.36	2.16	7.07
mediana	14.91	1.8	5.24
percentil_95	25.46	4.88	17.73
percentil_99	30.69	5.81	26.07

Tabla 3.3: Estadísticas descriptivas del nuevo parámetro de medida

Se puede observar que en general la media de las tres fuentes de fondeo analizadas es superior a la mediana lo que permite identificar de manera preliminar, que la distribución empírica de las series analizadas son sesgadas hacia la derecha (sesgo positivo).

También se puede evidenciar que la serie de depósitos a plazo es menos volátil que las series de depósitos corriente y de ahorros, dado que el máximo retiro diario que ha ocurrido durante una ventana temporal de 90 días fue del 7.72% con respecto al saldo del día anterior que se mantenía en la cuenta de depósito a plazo, mientras que el máximo retiro para las series de depósitos corriente y de ahorros fue del 33.02% y 33.01%, respectivamente; es decir, presentan valores similares y superiores al indicador de depósitos a plazo en aproximadamente 4.3 veces.

Capítulo 4

MODELO PARA LA MEDIA Y VARIANZA CONDICIONAL

4.1. PRUEBA DE RAÍCES UNITARIAS

Para cada fuente de fondeo analizada: corriente, a plazo y ahorros, se efectuó la prueba de raíces unitarias para tres tipos de modelos:

- Modelo con constante y tendencia.
- Modelo solo con constante.
- Modelo sin constante ni tendencia.

Para identificar el modelo que resulte válido, se realizan tres tipos de pruebas estadísticas:

- Significancia de los coeficientes.
- Prueba de hipótesis para rechazar o aceptar la existencia de raíces unitarias.
- Prueba Loglikelihood (logLik), Akaike (AIC) y Schwarz (BIC).

Para rechazar o aceptar la existencia de raíces unitarias, se plantea la siguiente prueba de hipótesis:

H0: $\delta = 0$ existen raíces unitarias.

H1: $\delta < 0$ no existen raíces unitarias.

Si $w = \{\tau < F\}$ se rechaza la hipótesis nula

A continuación, se describen los cálculos y los resultados de cada uno de los modelos que fueron analizados para cada fuente de fondeo.

4.1.1. RAÍCES UNITARIAS: DEPÓSITOS CORRIENTE

Modelo con constante y tendencia

```
> corriente.ct <- ur.df(ts.corriente, lags =0, type="trend",
+                       selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(corriente)
> scr <-sum(corriente.ct@res^2)
> corriente.logLik.ct <- logLik(eval(call("lm",
+                                       corriente.ct@testreg)))
> corriente.AIC.ct <- n + n*log(2*pi) + n*log(scr/n) + 2 * 5
> corriente.BIC.ct <- n + n*log(2*pi) + n*log(scr/n) + log(n)*5
> corriente.coef.ct <- round(corriente.ct@testreg$coefficients,4)
> corriente.testdf.ct <- round(c(corriente.ct@teststat[1],
+                               corriente.ct@cval[1,]),3)
```

Modelo solo con constante

```
> corriente.c <- ur.df(ts.corriente, lags =0, type="drift",
+                     selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(corriente)
> scr <-sum(corriente.c@res^2)
> corriente.logLik.c <- logLik(eval(call("lm",
+                                       corriente.c@testreg)))
> corriente.AIC.c <- n + n*log(2*pi) + n*log(scr/n) + 2 * 3
> corriente.BIC.c <- n + n*log(2*pi) + n*log(scr/n) +log(n)*3
> corriente.coef.c <- round(corriente.c@testreg$coefficients,4)
> corriente.testdf.c <- round(c(corriente.c@teststat[1],
+                               corriente.c@cval[1,]),3)
```

Modelo sin constante ni tendencia

```

> corriente.none <- ur.df(ts.corriente, lags =0, type="none",
+                          selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(corriente)
> scr <-sum(corriente.none@res^2)
> corriente.logLik.none <- logLik(eval(call("lm",
+                                          corriente.none@testreg)))
> corriente.AIC.none <- n + n*log(2*pi) + n*log(scr/n) + 2 * 2
> corriente.BIC.none <- n + n*log(2*pi) + n*log(scr/n) + log(n)*2
> corriente.coef.none <- round(corriente.none@testreg$coefficients,4)
> corriente.testdf.none <- round(c(corriente.none@teststat[1],
+                                  corriente.none@cval[1,]),3)

```

Resultados.- Los resultados que se obtuvieron de los coeficientes, así como los respectivos estadísticos en cada modelo son:

	Estad.Tau	Val.Crit.1 %	Val.Crit.5 %	Val.Crit.10 %
Const. y Tend.	-8.19	-4.04	-3.45	-3.15
Const.	-7.59	-3.51	-2.89	-2.58
Ninguno	-1.71	-2.60	-1.95	-1.61

Tabla 4.1: Corriente: estadístico Tau y valores críticos 1 %, 5 % y 10 %

Para el caso del modelo con constante y con tendencia, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ para el caso del 1 %, 5 % y 10 % de significancia; consecuentemente, se rechaza la hipótesis nula, es decir no existen raíces unitarias.

Para el caso del modelo únicamente con constante, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ para el caso del 1 %, 5 % y 10 % de significancia; consecuentemente, se rechaza la hipótesis nula, es decir no existen raíces unitarias.

Para el caso del modelo sin constante y sin tendencia, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ únicamente para el caso del 10 % de significancia; consecuentemente, no se rechaza la hipótesis nula para niveles de significancia del 1 % y 5 %, es decir existen raíces unitarias.

	Estimacion	Std.Error	Estad.t	Prob
Constante	0.12	0.02	6.65	0.00
Prueba(-1)	-0.87	0.11	-8.19	0.00
Tendencia	0.00	0.00	2.49	0.01

Tabla 4.2: Corriente: modelo con tendencia y constante

Con un nivel de significancia del 1 % los dos primeros coeficientes del modelo con constante y con tendencia son menores a 0.01 y el último (la tendencia) no es menor a 0.01; por lo tanto, no se rechaza la hipótesis nula que sea igual a cero, es decir, el último coeficiente resulta no significativo.

	Estimacion	Std.Error	Estad.t	Prob
Constante	0.13	0.02	7.28	0.00
Prueba(-1)	-0.80	0.11	-7.59	0.00

Tabla 4.3: Corriente: modelo con constante

Con un nivel de significancia del 1 % los coeficientes del modelo únicamente constante son menores a 0.01, por lo tanto, se rechaza la hipótesis nula que sean igual a cero, es decir los dos coeficientes son significantes.

	Estimacion	Std.Error	Estad.t	Prob
Prueba(-1)	-0.07	0.04	-1.71	0.09

Tabla 4.4: Corriente: modelo sin tendencia ni constante

Con un nivel de significancia del 1 % el coeficiente del modelo sin constante y sin tendencia es mayor 0.01, por lo tanto, no se rechaza la hipótesis nula que sea igual a cero, es decir, este coeficiente no es significativo.

	Modelo	logLik	AIC	BIC
1	Const y Tend	146.1	-3.18	-3.16
2	Const	143.01	-2.71	-3.07
3	Ninguno	121.86	-3.04	-2.65

Tabla 4.5: Corriente: prueba Loglikelihood, Akaike y Schwarz

Con respecto a las pruebas de Loglikelihood, AIC y BIC, se tiene que el modelo con constante y con tendencia presenta los mejores indicadores en las tres pruebas, es decir, presenta el máximo Loglikelihood y el mínimo AIC y

BIC, seguido del modelo únicamente con constante; y, finalmente el modelo sin constante y sin tendencia.

Se concluye que a través de la prueba de raíces unitarias, no es necesario diferenciar la serie depósitos corriente; y, se selecciona al modelo con constante dado que presenta el mejor ajuste en todas las pruebas de validación: pruebas de significancia de los coeficientes, pruebas de hipótesis para rechazar o aceptar la existencia de raíces unitarias; y, en las pruebas del estimador de máxima verosimilitud que minimiza la varianza (Loglikelihood) y de los criterios de información Akaike (AIC) y Schwarz (BIC).

4.1.2. RAÍCES UNITARIAS: DEPÓSITOS A PLAZO

Modelo con constante y tendencia

```
> plazo.ct <- ur.df(ts.plazo, lags =0, type="trend",
+                 selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(plazo)
> scr <-sum(plazo.ct@res^2)
> plazo.logLik.ct <- logLik(eval(call("lm",
+                                 plazo.ct@testreg)))
> plazo.AIC.ct <- n + n*log(2*pi) + n*log(scr/n) + 2 * 5
> plazo.BIC.ct <- n + n*log(2*pi) + n*log(scr/n) + log(n)*5
> plazo.coef.ct <- round(plazo.ct@testreg$coefficients,4)
> plazo.testdf.ct <- round(c(plazo.ct@teststat[1],
+                             plazo.ct@cval[1,]),3)
```

Modelo solo con constante

```
> plazo.c <- ur.df(ts.plazo, lags =0, type="drift",
+                 selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(plazo)
> scr <-sum(plazo.c@res^2)
> plazo.logLik.c <- logLik(eval(call("lm",
+                                 plazo.c@testreg)))
> plazo.AIC.c <- n + n*log(2*pi) + n*log(scr/n) + 2 * 3
```

```
> plazo.BIC.c <- n + n*log(2*pi) + n*log(scr/n) + log(n)*3
> plazo.coef.c <- round(plazo.c@testreg$coefficients,4)
> plazo.testdf.c <- round(c(plazo.c@teststat[1],
+                           plazo.c@cval[1,]),3)
```

Modelo sin constante ni tendencia

```
> plazo.none <- ur.df(ts.plazo, lags =0, type="none",
+                   selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(plazo)
> scr <- sum(plazo.none@res^2)
> plazo.logLik.none <- logLik(eval(call("lm",
+                                       plazo.none@testreg)))
> plazo.AIC.none <- n + n*log(2*pi) + n*log(scr/n) + 2 * 2
> plazo.BIC.none <- n + n*log(2*pi) + n*log(scr/n) + log(n)*2
> plazo.coef.none <- round(plazo.none@testreg$coefficients,4)
> plazo.testdf.none <- round(c(plazo.none@teststat[1],
+                               plazo.none@cval[1,]),3)
```

Resultados.- Los resultados que se obtuvieron de los coeficientes, así como los respectivos estadísticos en cada modelo son:

	Estad.Tau	Val.Crit.1 %	Val.Crit.5 %	Val.Crit.10 %
Const. y Tend.	-8.19	-4.04	-3.45	-3.15
Const.	-7.59	-3.51	-2.89	-2.58
Ninguno	-1.71	-2.60	-1.95	-1.61

Tabla 4.6: Plazo: estadístico Tau y valores críticos 1 %, 5 % y 10 %

Para el caso del modelo con constante y con tendencia, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ para el caso del 1 %, 5 % y 10 % de significancia; consecuentemente, se rechaza la hipótesis nula, es decir no existen raíces unitarias.

Para el caso del modelo únicamente con constante, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ para el caso del 1 %, 5 % y 10 %

de significancia; consecuentemente, se rechaza la hipótesis nula, es decir no existen raíces unitarias.

Para el caso del modelo sin constante y sin tendencia, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ únicamente para el caso del 10 % de significancia; consecuentemente, no se rechaza la hipótesis nula para niveles de significancia del 1 % y 5 %, es decir existen raíces unitarias.

	Estimacion	Std.Error	Estad.t	Prob
Constante	0.02	0.00	6.30	0.00
Prueba(-1)	-1.06	0.11	-9.87	0.00
Tendencia	-0.00	0.00	-0.62	0.54

Tabla 4.7: Plazo: modelo con tendencia y constante

Con un nivel de significancia del 1 % los dos primeros coeficientes del modelo con constante y con tendencia son menores a 0.01 y el último (la tendencia) no es menor a 0.01; por lo tanto, no se rechaza la hipótesis nula que sea igual a cero, es decir, el último coeficiente resulta no significativo.

	Estimacion	Std.Error	Estad.t	Prob
Constante	0.02	0.00	8.31	0.00
Prueba(-1)	-1.06	0.11	-9.89	0.00

Tabla 4.8: Plazo: modelo con constante

Con un nivel de significancia del 1 % los coeficientes del modelo únicamente constante son menores a 0.01, por lo tanto, se rechaza la hipótesis nula que sean igual a cero, es decir los dos coeficientes son significantes.

	Estimacion	Std.Error	Estad.t	Prob
Prueba(-1)	-0.31	0.08	-4.03	0.00

Tabla 4.9: Plazo: modelo sin tendencia ni constante

Con un nivel de significancia del 1 % el coeficiente del modelo sin constante y sin tendencia es menor a 0.01, por lo tanto, se rechaza la hipótesis nula que sea igual a cero, es decir, este coeficiente es significativo.

Modelo solo con constante

```

> ahorros.c <- ur.df(ts.ahorros, lags =0, type="drift",
+                   selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(ahorros)
> scr <-sum(ahorros.c@res^2)
> ahorros.logLik.c <- logLik(eval(call("lm",
+                                   ahorros.c@testreg)))
> ahorros.AIC.c <- n + n*log(2*pi) + n*log(scr/n) + 2 * 3
> ahorros.BIC.c <- n + n*log(2*pi) + n*log(scr/n) +log(n)*3
> ahorros.coef.c <- round(ahorros.c@testreg$coefficients,4)
> ahorros.testdf.c <- round(c(ahorros.c@teststat[1],
+                             ahorros.c@cval[1,]),3)

```

Modelo sin constante ni tendencia

```

> ahorros.none <- ur.df(ts.ahorros, lags =0, type="none",
+                       selectlags = c("Fixed", "AIC", "BIC"))
> n <- length(ahorros)
> scr <-sum(ahorros.none@res^2)
> ahorros.logLik.none <- logLik(eval(call("lm",
+                                       ahorros.none@testreg)))
> ahorros.AIC.none <- n + n*log(2*pi) + n*log(scr/n) + 2 * 2
> ahorros.BIC.none <- n + n*log(2*pi) + n*log(scr/n) + log(n)*2
> ahorros.coef.none <- round(ahorros.none@testreg$coefficients,4)
> ahorros.testdf.none <- round(c(ahorros.none@teststat[1],
+                               ahorros.none@cval[1,]),3)

```

Resultados.- Los resultados que se obtuvieron de los coeficientes, así como los respectivos estadísticos en cada modelo son:

	Estad.Tau	Val.Crit.1 %	Val.Crit.5 %	Val.Crit.10 %
Const. y Tend.	-8.19	-4.04	-3.45	-3.15
Const.	-7.59	-3.51	-2.89	-2.58
Ninguno	-1.71	-2.60	-1.95	-1.61

Tabla 4.11: Ahorros: estadístico Tau y valores críticos 1 %, 5 % y 10 %

Para el caso del modelo con constante y con tendencia, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ para el caso del 1 %, 5 % y 10 % de significancia; consecuentemente, se rechaza la hipótesis nula, es decir no existen raíces unitarias.

Para el caso del modelo únicamente con constante, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ para el caso del 1 %, 5 % y 10 % de significancia; consecuentemente, se rechaza la hipótesis nula, es decir no existen raíces unitarias.

Para el caso del modelo sin constante y sin tendencia, se tiene que el estadístico de Tau es menor al valor crítico $F \{ \tau < F \}$ únicamente para el caso del 10 % de significancia; consecuentemente, no se rechaza la hipótesis nula para niveles de significancia del 1 % y 5 %, es decir existen raíces unitarias.

	Estimacion	Std.Error	Estad.t	Prob
Constante	0.04	0.01	3.48	0.00
Prueba(-1)	-0.72	0.10	-7.12	0.00
Tendencia	0.00	0.00	0.75	0.46

Tabla 4.12: Ahorros: modelo con tendencia y constante

Con un nivel de significancia del 1 % los dos primeros coeficientes del modelo con constante y con tendencia son menores a 0.01 y el último (la tendencia) no es menor a 0.01; por lo tanto, no se rechaza la hipótesis nula que sea igual a cero, es decir, el último coeficiente resulta no significativo.

	Estimacion	Std.Error	Estad.t	Prob
Constante	0.05	0.01	5.62	0.00
Prueba(-1)	-0.71	0.10	-7.11	0.00

Tabla 4.13: Ahorros: modelo con constante

Con un nivel de significancia del 1 % los coeficientes del modelo únicamente constante son menores a 0.01, por lo tanto, se rechaza la hipótesis nula que sean igual a cero, es decir los dos coeficientes son significantes.

	Estimacion	Std.Error	Estad.t	Prob
Prueba(-1)	-0.26	0.07	-3.76	0.00

Tabla 4.14: Ahorros: modelo sin tendencia ni constante

Con un nivel de significancia del 1 % el coeficiente del modelo sin constante y sin tendencia es menor a 0.01, por lo tanto, se rechaza la hipótesis nula que sea igual a cero, es decir, este coeficiente es significativo.

	Modelo	logLik	AIC	BIC
1	Const y Tend	144.49	-3.15	-3.19
2	Const	144.21	-2.9	-3.1
3	Ninguno	130.43	-3.01	-2.84

Tabla 4.15: Ahorros: prueba Loglikelihood, Akaike y Schwarz

Con respecto a las pruebas de Loglikelihood, AIC y BIC, se tiene que el modelo con constante y con tendencia presenta los mejores indicadores en las tres pruebas, es decir, presenta el máximo Loglikelihood y el mínimo AIC y BIC, seguido del modelo únicamente con constante; y, finalmente el modelo sin constante y sin tendencia.

Se concluye que a través de la prueba de raíces unitarias, no es necesario diferenciar la serie depósitos de ahorros; y, se selecciona al modelo con constante dado que presenta el mejor ajuste en todas las pruebas de validación: pruebas de significancia de los coeficientes, pruebas de hipótesis para rechazar o aceptar la existencia de raíces unitarias; y, en las pruebas del estimador de máxima verosimilitud que minimiza la varianza (Loglikelihood) y de los criterios de información Akaike (AIC) y Schwarz (BIC).

4.2. MEDIA CONDICIONAL: DEPÓSITOS CORRIENTE

Con el fin de establecer si existe autocorrelación en la serie depósitos corriente, se realizó un análisis preliminar de las funciones de autocorrelación y autocorrelación parcial, tanto de la serie original como de la serie logarítmica, a continuación se presenta el gráfico y la tabla de resultados:




Figura 4.1: Serie depósitos corriente

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.19889	0.01715	11	-0.02333	0.03624
2	0.03364	0.12723	12	0.11858	0.06594
3	0.11066	0.02514	13	-0.00847	0.09463
4	0.09569	-0.05217	14	-0.11176	-0.09158
5	-0.09768	-0.04360	15	-0.02097	-0.04930
6	-0.03498	-0.12381	16	-0.11731	0.11454
7	0.02159	-0.00931	17	-0.02333	0.08803
8	0.04130	-0.10728	18	-0.09049	-0.02905
9	-0.06857	-0.04790	19	-0.06123	0.07093
10	0.03558	0.19889			

Tabla 4.16: Autocorrelación y Autocorrelación Parcial: depósitos corriente

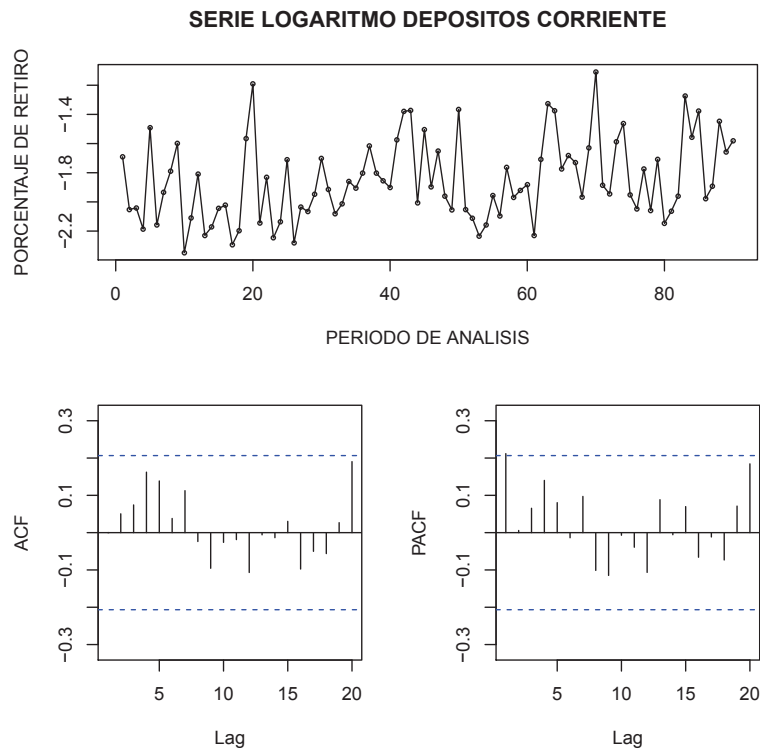


Figura 4.2: Serie logaritmo depósitos corriente

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.21182	0.21182	11	-0.01863	-0.03909
2	0.05047	0.00587	12	-0.10678	-0.10657
3	0.07431	0.06537	13	-0.00587	0.08838
4	0.16222	0.14001	14	-0.01353	-0.00557
5	0.13855	0.08041	15	0.03029	0.06985
6	0.03803	-0.01370	16	-0.09756	-0.06590
7	0.11257	0.09710	17	-0.05010	-0.01158
8	-0.02372	-0.10121	18	-0.05614	-0.07329
9	-0.09552	-0.11463	19	0.02678	0.07122
10	-0.02605	-0.00692			

Tabla 4.17: Autocorrelación y Autocorrelación Parcial: log. depósitos corriente

4.2.1. MODELO ARMA: LOGARITMO DE LA SERIE DEPÓSITOS CORRIENTE

En el **Anexo A** se describen los modelos de series de tiempo que no fueron seleccionados tanto para la serie original como para la serie logarítmica de depósitos corriente. En este sentido, a continuación se presenta únicamente el modelo $\text{arma}(1,0)$ que fue seleccionado para la serie logarítmica de depósitos corriente:

```
> ar.corriente <- arma(log(ts.corriente),order=c(1,0),
+                       include.intercept = TRUE)
> resid.corriente<-ar.corriente$residuals[-1]
> residsqr.corriente<-resid.corriente*resid.corriente
```

Call:

```
arma(x=log(ts.corriente), order=c(1,0), include.intercept=TRUE)
```

Model:

```
ARMA(1,0)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-0.55059	-0.20061	-0.04859	0.20282	0.69619

Coefficient(s):

	Estimate	Std. Error	t value	Pr(> t)
ar1	0.2140	0.1033	2.071	0.0384
intercept	-1.4558	0.1937	-7.515	5.68e-14

Fit:

σ^2 estimated as 0.07543,

Conditional Sum-of-Squares = 6.64, AIC = 26.8

4.2.2. PRUEBA ESTADÍSTICA DE BOX PIERCE - LJUNG BOX

Una vez que se ha definido el modelo que se aplicará a la serie logarítmica de depósitos corriente, se efectúa la prueba estadística de Box Pierce - Ljung Box, con el fin de examinar la siguiente prueba de hipótesis:

H0: Las observaciones son independientes.

H1: Las observaciones no son independientes.

Si $\{p - valor < \alpha\}$ se rechaza la hipótesis nula, para $\alpha = 0.05$. En las tablas 4.18, 4.19 y 4.20, se presenta los resultados de la prueba de Box Pierce - Ljung Box, que se aplicó tanto a la serie logarítmica como a los residuos y a los residuos al cuadrado del modelo arma(1,0).

Retardo	p-valor	Retardo	p-valor
1	0.1184	11	0.4360
2	0.1899	12	0.5175
3	0.1290	13	0.5950
4	0.1148	14	0.6620
5	0.1741	15	0.6669
6	0.1813	16	0.7155
7	0.2525	17	0.7554
8	0.2755	18	0.8035
9	0.3526	19	0.6583
10	0.4353		

Tabla 4.18: Prueba de Box Pierce - Ljung Box: Log. depósitos corriente

Retardo	p-valor	Retardo	p-valor
1	0.9983	11	0.9392
2	0.9808	12	0.9609
3	0.8341	13	0.9761
4	0.7574	14	0.9814
5	0.8529	15	0.9788
6	0.7891	16	0.9871
7	0.8569	17	0.9897
8	0.8685	18	0.9938
9	0.9168	19	0.9665
10	0.9493		

Tabla 4.19: Prueba de Box Pierce - Ljung Box: Residuos depósitos corriente

Retardo	p-valor	Retardo	p-valor
1	0.6697	11	0.9351
2	0.7536	12	0.8778
3	0.7295	13	0.8577
4	0.8339	14	0.8767
5	0.9047	15	0.9045
6	0.9209	16	0.8920
7	0.9454	17	0.9165
8	0.9708	18	0.9412
9	0.9842	19	0.8664
10	0.9881		

Tabla 4.20: Prueba de Box Pierce - Ljung Box: Residuos al cuadrado depósitos corriente

Al aplicar la prueba de Box Pierce - Ljung Box, se pudo determinar que tanto para la serie logarítmica como para las series de los residuos y de los residuos al cuadrado del modelo arma(1,0), el p-valor de cada uno de los retardos es superior a $\alpha = 0.05$; consecuentemente, tanto la serie logarítmica de los depósitos corriente como los residuos y los residuos al cuadrado del modelo arma(1,0) son independientes dado que no se rechaza la hipótesis nula.

4.2.3. AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO ARMA

Se verifica la existencia de autocorrelación y autocorrelación parcial, a través del gráfico y de la respectiva tabla de los residuos y de los residuos al cuadrado del modelo arma(1,0) del logaritmo de la serie depósitos corriente:

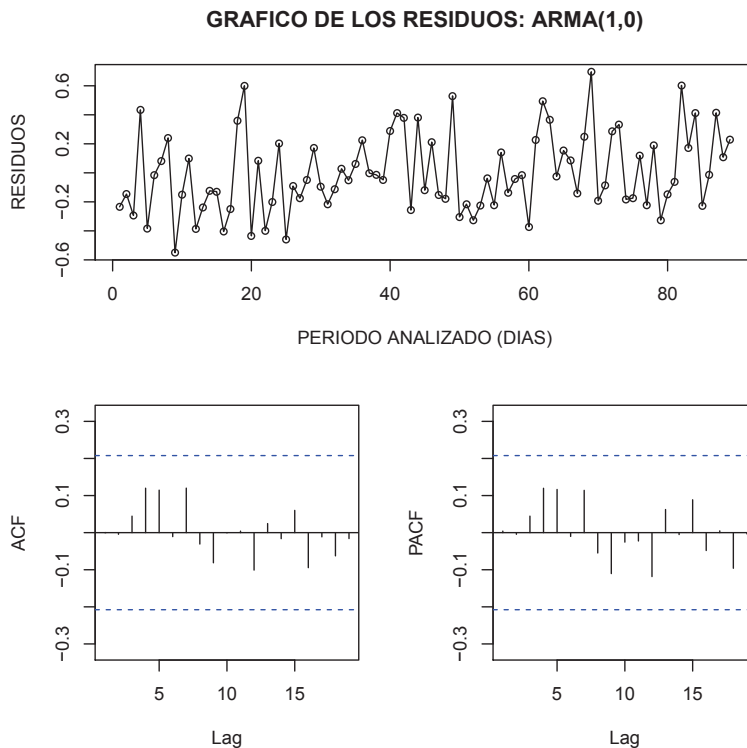


Figura 4.3: Residuos del modelo arma(1,0) de log. corriente

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.00421	0.00421	11	0.00415	-0.02245
2	-0.00440	-0.00442	12	-0.10095	-0.11841
3	0.04452	0.04456	13	0.02450	0.06240
4	0.11983	0.11967	14	-0.01627	-0.00515
5	0.11459	0.11647	15	0.06004	0.08863
6	-0.01076	-0.01021	16	-0.09443	-0.04822
7	0.12003	0.11403	17	-0.01138	0.00482
8	-0.03072	-0.05483	18	-0.06258	-0.09602
9	-0.08125	-0.11036	19	-0.01596	-0.00337
10	-0.00069	-0.02558			

Tabla 4.21: Autocorrelación y Autocorrelación Parcial: Residuos




Figura 4.4: Residuos al cuadrado del modelo arma(1,0) de log. corriente

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.02191	0.02191	11	-0.05841	-0.03489
2	-0.09236	-0.09288	12	-0.16472	-0.17973
3	0.06666	0.07156	13	0.14414	0.16392
4	-0.09694	-0.11086	14	-0.11233	-0.18681
5	-0.02904	-0.00919	15	-0.07094	0.01608
6	-0.02338	-0.04863	16	-0.04674	-0.17208
7	0.06897	0.08469	17	-0.10902	-0.04078
8	-0.05130	-0.07545	18	-0.04424	-0.13067
9	-0.01102	0.01256	19	-0.00246	0.05129
10	0.02408	-0.00968			

Tabla 4.22: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado

4.2.4. PRUEBAS DE NORMALIDAD DE LOS ERRORES

Con esta prueba se requiere verificar si los residuos siguen una distribución normal, planteándose la siguiente hipótesis:

H₀: Los residuos siguen una distribución $N(\mu, \sigma)$

H_a: Los residuos no siguen una distribución $N(\mu, \sigma)$

Para el efecto, se calcularon tres pruebas estadísticas que permitan confirmar o negar la hipótesis nula: la prueba de Shapiro-Wilk, la prueba de Kolmogorov Smirnov (KS) y la prueba de Anderson Darling (AD),

Shapiro-Wilk: $W = 0.9733$, p-valor = 0.06364.

Kolmogorov-Smirnov: $D = 0.1045$, p-valor = 0.2663.

Anderson-Darling: $AD = 0.8642$, p-valor = 0.4366.

Se concluye que para el caso de las tres pruebas de normalidad aplicadas los valores críticos son superiores a $\alpha = 0.05$; por lo tanto, los residuos siguen una distribución $N(\mu, \sigma)$ dado que no se rechaza la hipótesis nula.

Adicionalmente, se presenta el histograma y el gráfico de cuantiles de los residuales:

```
> par(mfrow=c(1,2))
> hist(resid.corriente,main="HISTOGRAMA",
+       xlab="RESIDUOS",ylab="FRECUENCIA",cex=0.95)
> qqnorm(resid.corriente,main="GRAFICO Q-Q",
+         xlab="CUANTILES TEORICOS",
+         ylab="MUESTRA DE LOS CUANTILES",cex=0.95)
> qqline(resid.corriente)
```

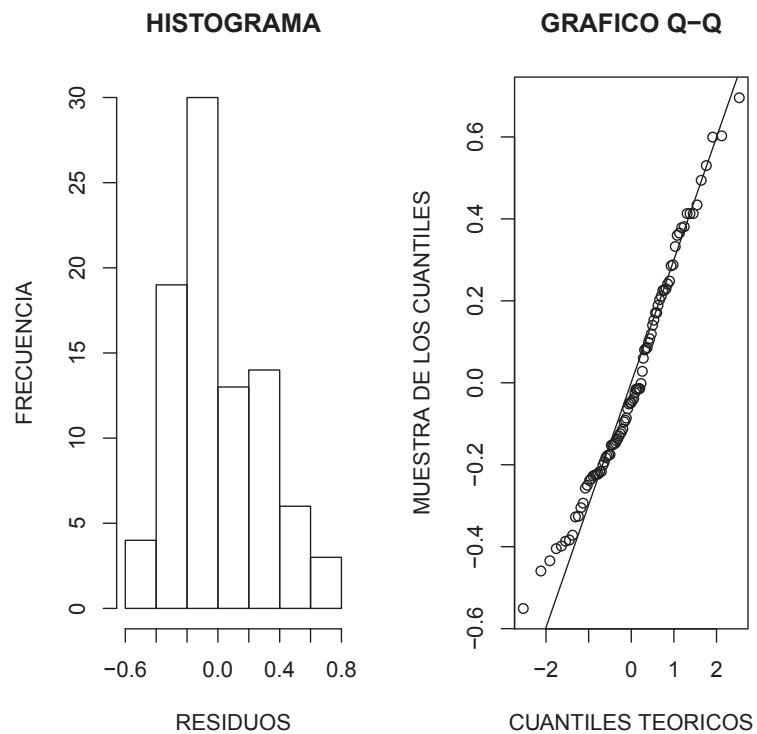


Figura 4.5: Histograma de residuales y Gráfico Q-Q de residuales

4.2.5. SELECCIÓN DEL MEJOR MODELO: DEPÓSITOS CORRIENTE

Se seleccionó el mejor modelo en función de las siguientes consideraciones:

- acf y pacf de residuos estan dentro de las bandas, por lo tanto no presentan autocorrelación.
- acf y pacf de residuos al cuadrado estan dentro de las bandas, por lo tanto no presentan autocorrelación.
- A través de la prueba box.test se acepta H_0 : Los residuos son independientes.
- A través de la prueba box.test se acepta H_0 : Los residuos al cuadrado son independientes.
- El p-value de shapiro.test >0.05 por lo tanto los residuos se ajustan a una distribución normal.

- El p-value del test KS >0.05 por lo tanto los residuos se ajustan a una distribución normal.
- El p-value del test AD >0.05 por lo tanto los residuos se ajustan a una distribución normal.

4.2.6. PREDICCIÓN DE LA SERIE DEPÓSITOS CORRIENTE

La ecuación (4.1) permite predecir el logaritmo de la variación de los depósitos corriente en el tiempo (t):

$$x_t = -1.4558 + 0.2140 * x_{t-1} + \mu_t \quad (4.1)$$

Donde:

x_t → logaritmo de la serie depósitos corriente en el tiempo (t)

x_{t-1} → logaritmo de la serie depósitos corriente en el tiempo (t-1)

μ_t → término de error de la ecuación

Para $t = 1, 2, 3, 4, 5, \dots$, 91 días de cálculo.

La implementación de la ecuación antes descrita es:

```
> predcorriente<-matrix(nrow=88,ncol=1)
> u<-resid.corriente
> x<-log(ts.corriente)[-1]
> beta0<-ar.corriente$coef[[2]]
> alfa<-ar.corriente$coef[[1]]
> for (i in 1:88) {predcorriente[i]<-beta0+alfa*x[i]+u[i+1]}
> ts.predcorriente<-ts(predcorriente)
```

En el gráfico 4.6 , se presentan los datos pronosticados versus los datos reales del logaritmo de la variación lineal de la serie depósitos corriente.

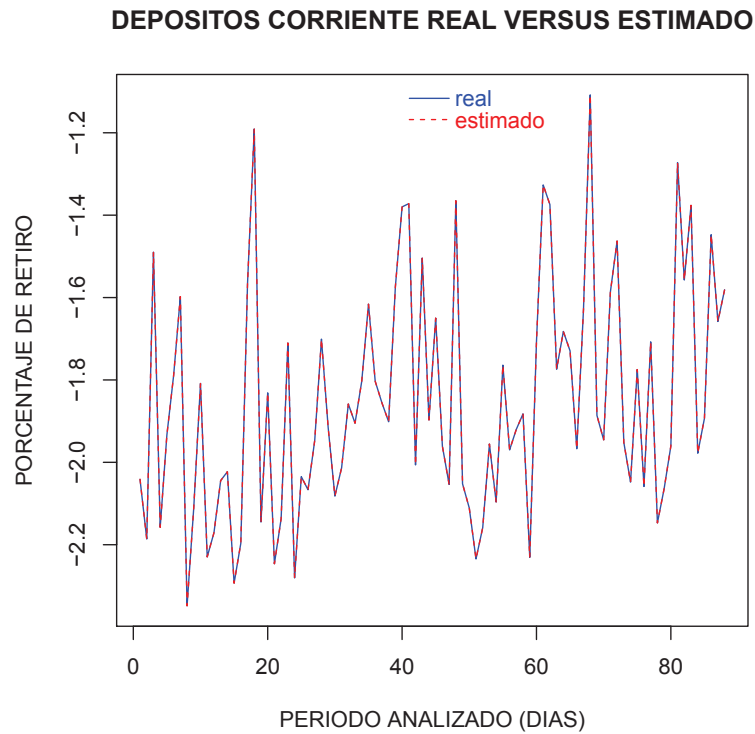


Figura 4.6: Predicción serie depósitos corriente

4.3. MEDIA CONDICIONAL: DEPÓSITOS A PLAZO

Con el fin de establecer si existe autocorrelación en la serie depósitos a plazo, se realizó un análisis preliminar de las funciones de autocorrelación y autocorrelación parcial, tanto de la serie original como de la serie logarítmica, a continuación se presenta el gráfico y la tabla de resultados:




Figura 4.7: Serie depósitos a plazo

Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.05639	-0.05639	11	-0.02964	0.02988
2	-0.00202	-0.00522	12	0.14669	0.07814
3	0.07227	0.07210	13	-0.04762	-0.01297
4	-0.01988	-0.01185	14	-0.01369	-0.14736
5	0.06720	0.06622	15	0.10315	0.15537
6	-0.19904	-0.19950	16	0.07791	0.01289
7	-0.08525	-0.10735	17	-0.14165	-0.14341
8	-0.17688	-0.21203	18	0.05716	-0.00242
9	0.14079	0.16206	19	-0.05267	0.02241
10	-0.16799	-0.17087			

Tabla 4.23: Autocorrelación y Autocorrelación Parcial: Serie depósitos a plazo

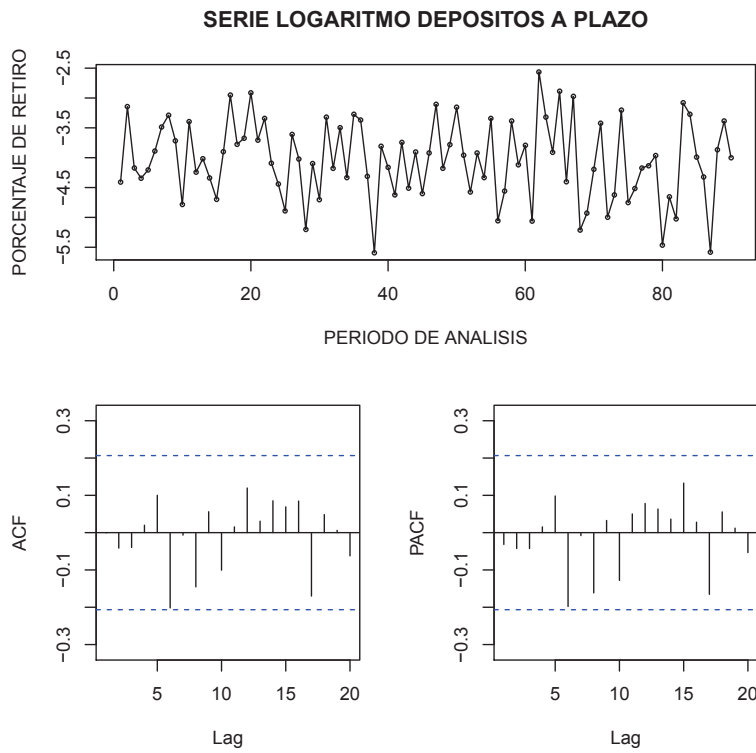


Figura 4.8: Serie logaritmo depósitos a plazo

Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.03169	-0.03169	11	0.01543	0.05018
2	-0.04144	-0.04249	12	0.11969	0.07826
3	-0.03971	-0.04255	13	0.03068	0.06331
4	0.01996	0.01548	14	0.08544	0.03630
5	0.10012	0.09831	15	0.06907	0.13270
6	-0.20184	-0.19795	16	0.08468	0.02808
7	-0.00661	-0.00792	17	-0.16992	-0.16534
8	-0.14530	-0.16154	18	0.04836	0.05558
9	0.05606	0.03266	19	0.00624	0.01211
10	-0.10057	-0.12797			

Tabla 4.24: Autocorrelación y Autocorrelación Parcial: Serie log. depósitos plazo

4.3.1. MODELO ARMA: LOGARITMO DE LA SERIE DEPÓSITOS A PLAZO

En el **Anexo A** se describen los modelos de series de tiempo que no fueron seleccionados tanto para la serie original como para la serie logarítmica de depósitos a plazo. En este sentido, a continuación se presenta únicamente el modelo arma(1,0) que fue seleccionado para la serie logarítmica de depósitos a plazo:

```
> ar.plazo <- arma(log(ts.plazo),order=c(1,0),
+                 include.intercept = TRUE)
> resid.plazo<-ar.plazo$residuals[-1]
> residssqr.plazo<-resid.plazo*resid.plazo
```

Call:

```
arma(x=log(ts.plazo), order=c(1, 0), include.intercept=TRUE)
```

Model: ARMA(1,0)

Residuals:

	Min	1Q	Median	3Q	Max
	-1.56279	-0.46281	0.02883	0.55871	1.44335

Coefficient(s):

	Estimate	Std. Error	t value	Pr(> t)
ar1	-0.03156	0.10518	-0.300	0.764
intercept	-4.16468	0.43077	-9.668	<2e-16

Fit:

sigma^2 estimated as 0.4426,

Conditional Sum-of-Squares = 38.95, AIC = 186.05

4.3.2. PRUEBA ESTADÍSTICA DE BOX PIERCE - LJUNG BOX

Una vez que se ha definido el modelo que se aplicará a la serie logarítmica de depósitos a plazo, se efectúa la prueba estadística de Box Pierce - Ljung

Box, con el fin de examinar la siguiente prueba de hipótesis:

H0: Las observaciones son independientes.

H1: Las observaciones no son independientes.

Si $\{p - \text{valor} < \alpha\}$ se rechaza la hipótesis nula, para $\alpha = 0.05$. En las tablas 4.25, 4.26 y 4.25, se presenta los resultados de la prueba de Box Pierce - Ljung Box, que se aplicó tanto a la serie logarítmica como a los residuos y a los residuos al cuadrado del modelo arma(1,0).

Retardo	p-valor	Retardo	p-valor
1	0.8847	11	0.6685
2	0.9429	12	0.7355
3	0.9806	13	0.7518
4	0.9323	14	0.7824
5	0.5449	15	0.7960
6	0.6605	16	0.6802
7	0.5480	17	0.7275
8	0.6186	18	0.7820
9	0.6202	19	0.8109
10	0.7034		

Tabla 4.25: Prueba de Box Pierce - Ljung Box: Log. depósitos a plazo

Retardo	p-valor	Retardo	p-valor
1	0.9126	11	0.7343
2	0.9503	12	0.7927
3	0.9835	13	0.8085
4	0.9438	14	0.8289
5	0.5980	15	0.8331
6	0.7093	16	0.7363
7	0.6065	17	0.7799
8	0.6870	18	0.8272
9	0.6980	19	0.8518
10	0.7738		

Tabla 4.26: Prueba de Box Pierce - Ljung Box: Residuos depósitos a plazo

Retardo	p-valor	Retardo	p-valor
1	0.5384	11	0.8693
2	0.6216	12	0.8948
3	0.6594	13	0.8588
4	0.7394	14	0.8780
5	0.8168	15	0.8427
6	0.5375	16	0.8408
7	0.6008	17	0.5046
8	0.6880	18	0.5534
9	0.7670	19	0.6148
10	0.8339		

Tabla 4.27: Prueba de Box Pierce - Ljung Box: Residuos al cuadrado depósitos a plazo

Al aplicar la prueba de Box Pierce - Ljung Box, se pudo determinar que tanto para la serie logarítmica como para las series de los residuos y de los residuos al cuadrado del modelo arma(1,0), el p-valor de cada uno de los retardos es superior a $\alpha = 0.05$; consecuentemente, tanto la serie logarítmica de los depósitos a plazo como los residuos y los residuos al cuadrado del modelo arma(1,0) son independientes dado que no se rechaza la hipótesis nula.

4.3.3. AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO ARMA

Se verifica la existencia de autocorrelación y autocorrelación parcial, a través del gráfico y de la respectiva tabla de los residuos y de los residuos al cuadrado del modelo arma(1,0) del logaritmo de la serie depósitos a plazo:

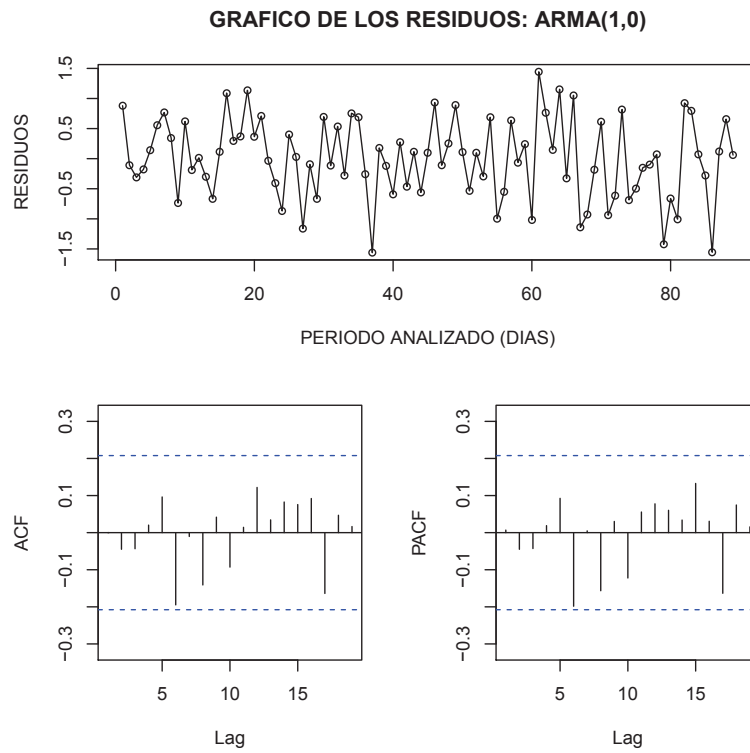


Figura 4.9: Gráfico de los residuos del modelo arma(1,0)

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.00690	0.00690	11	0.01437	0.05565
2	-0.04482	-0.04487	12	0.12191	0.07770
3	-0.04339	-0.04285	13	0.03443	0.06027
4	0.02031	0.01892	14	0.08263	0.03399
5	0.09619	0.09251	15	0.07575	0.13266
6	-0.19472	-0.19837	16	0.09207	0.03071
7	-0.01029	0.00480	17	-0.16392	-0.16352
8	-0.14101	-0.15656	18	0.04688	0.07454
9	0.04180	0.03023	19	0.01650	0.01551
10	-0.09290	-0.12225			

Tabla 4.28: Autocorrelación y Autocorrelación Parcial: Residuos

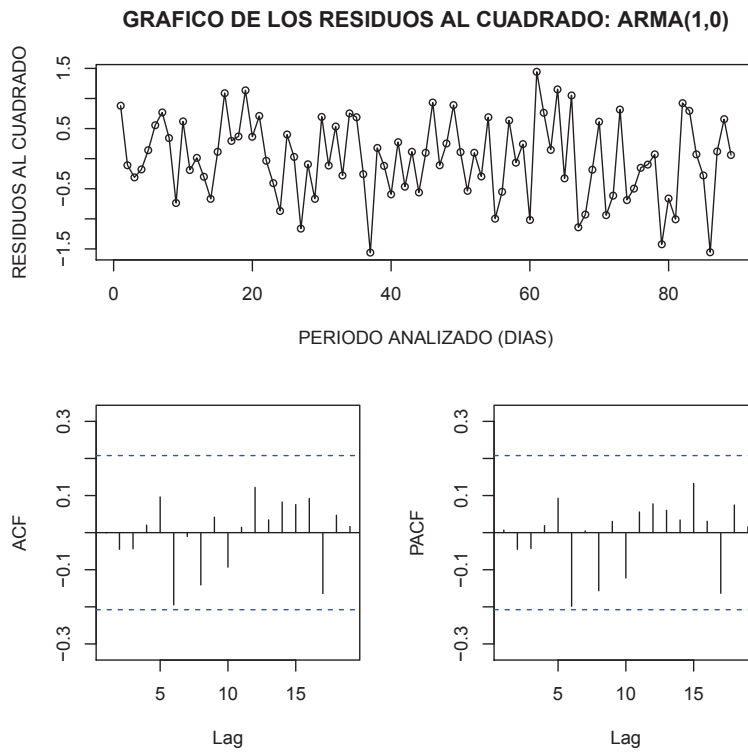


Figura 4.10: Gráfico de los residuos al cuadrado del modelo arma(1,0)

Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.10935	-0.10935	11	0.00674	0.03098
2	-0.04421	-0.05685	12	0.05450	0.02322
3	0.07725	0.06694	13	0.06003	0.06224
4	-0.08536	-0.07301	14	-0.12582	-0.16348
5	0.06053	0.05137	15	0.07037	0.08389
6	0.04652	0.04718	16	-0.12761	-0.13835
7	0.18610	0.21829	17	-0.09807	-0.07631
8	-0.06674	-0.03403	18	0.25912	0.18633
9	-0.03260	-0.02205	19	0.05483	0.14046
10	-0.02151	-0.06304			

Tabla 4.29: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado

4.3.4. PRUEBAS DE NORMALIDAD DE LOS ERRORES

Con esta prueba se requiere verificar si los residuos siguen una distribución normal, planteándose la siguiente hipótesis:

H₀: Los residuos siguen una distribución $N(\mu, \sigma)$

H_a: Los residuos no siguen una distribución $N(\mu, \sigma)$

Para el efecto, se calcularon tres pruebas estadísticas que permitan confirmar o negar la hipótesis nula: la prueba de Shapiro-Wilk, la prueba de Kolmogorov Smirnov (KS) y la prueba de Anderson Darling (AD),

Shapiro-Wilk: $W = 0.9863$, p-valor = 0.4787.

Kolmogorov-Smirnov: $D = 0.0702$, p-valor = 0.7452.

Anderson-Darling: $AD = 0.3252$, p-valor = 0.9179.

Se concluye que para el caso de las tres pruebas de normalidad aplicadas los valores críticos son superiores a $\alpha = 0.05$; por lo tanto, los residuos siguen una distribución $N(\mu, \sigma)$ dado que no se rechaza la hipótesis nula.

Adicionalmente, se presenta el histograma y el gráfico de cuantiles de los residuales:

```
> par(mfrow=c(1,2))
> hist(resid.plazo,main="HISTOGRAMA",
+       xlab="RESIDUOS",ylab="FRECUENCIA",cex=0.95)
> qqnorm(resid.plazo,main="GRAFICO Q-Q",
+        xlab="CUANTILES TEORICOS",
+        ylab="MUESTRA DE LOS CUANTILES",cex=0.95)
> qqline(resid.plazo)
```

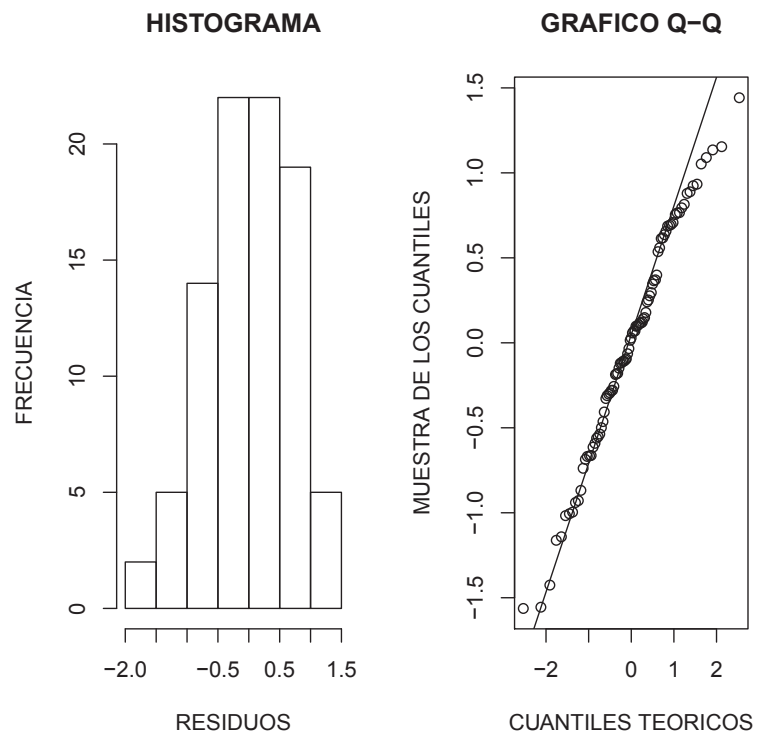


Figura 4.11: Histograma de residuales y Gráfico Q-Q de residuales

4.3.5. SELECCIÓN DEL MEJOR MODELO: DEPÓSITOS A PLAZO

Se seleccionó el mejor modelo en función de las siguientes consideraciones:

- acf y pacf de residuos estan dentro de las bandas, por lo tanto no presentan autocorrelación.
- acf y pacf de residuos al cuadrado estan dentro de las bandas, por lo tanto no presentan autocorrelación.
- A través de la prueba box.test se acepta H_0 : Los residuos son independientes.
- A través de la prueba box.test se acepta H_0 : Los residuos al cuadrado son independientes.
- El p-value de shapiro.test >0.05 por lo tanto los residuos se ajustan a una distribución normal.

- El p-value del test KS >0.05 por lo tanto los residuos se ajustan a una distribución normal.
- El p-value del test AD >0.05 por lo tanto los residuos se ajustan a una distribución normal.

4.3.6. PREDICCIÓN DE LA SERIE DEPÓSITOS A PLAZO

La ecuación (4.2) permite predecir el logaritmo de la variación de los depósitos a plazo en el tiempo (t):

$$x_t = -4.16468 - 0.03156 * x_{t-1} + \mu_t \quad (4.2)$$

Donde:

x_t → logaritmo de la serie depósitos a plazo en el tiempo (t)

x_{t-1} → logaritmo de la serie depósitos a plazo en el tiempo (t-1)

μ_t → término de error de la ecuación

Para $t = 1, 2, 3, 4, 5, \dots$, 91 días de cálculo.

La implementación de la ecuación antes descrita es:

```
> predplazo<-matrix(nrow=88,ncol=1)
> u<-resid.plazo
> x<-log(ts.plazo)[-1]
> beta0<-ar.plazo$coef[[2]]
> alfa<-ar.plazo$coef[[1]]
> for (i in 1:88) {predplazo[i]<-beta0+alfa*x[i]+u[i+1]}
> ts.predplazo<-ts(predplazo)
```

En el gráfico 4.12, se presentan los datos pronosticados versus los datos reales del logaritmo de la variación lineal de la serie depósitos a plazo.

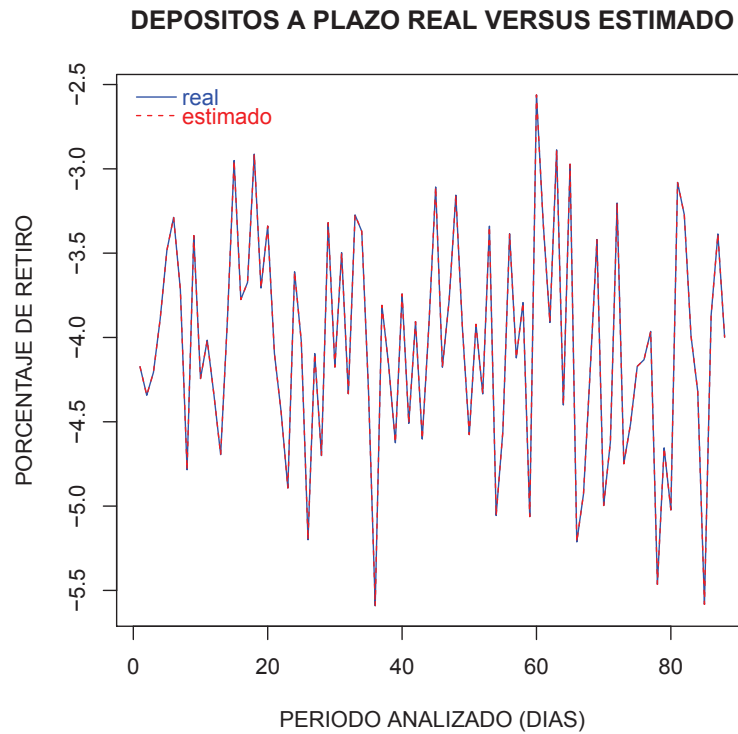


Figura 4.12: Predicción serie depósitos a plazo

4.4. MEDIA Y VARIANZA CONDICIONAL: AHORROS

Con el fin de establecer si existe autocorrelación en la serie depósitos corriente, se realizó un análisis preliminar de las funciones de autocorrelación y autocorrelación parcial, tanto de la serie original como de la serie logarítmica, a continuación se presenta el gráfico y la tabla de resultados:

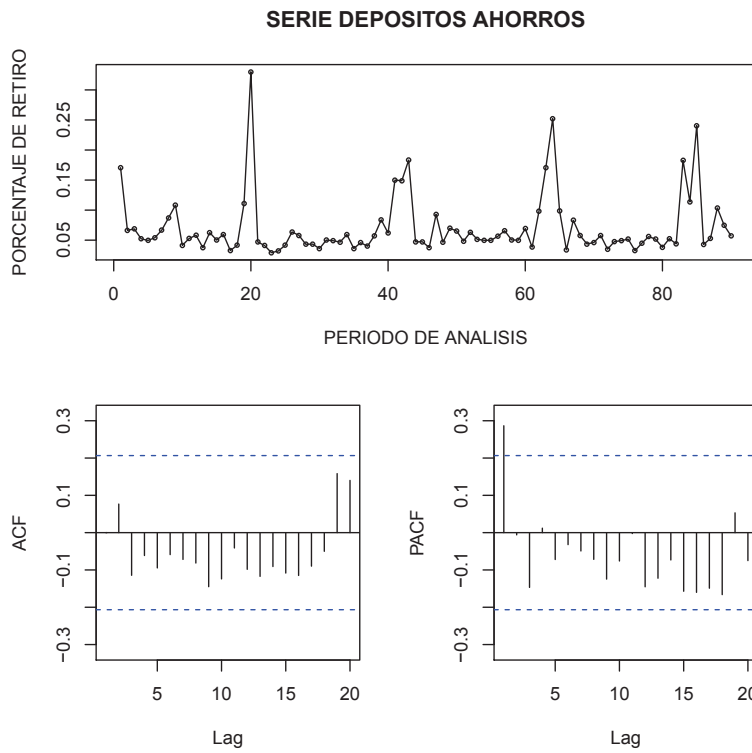


Figura 4.13: Serie depósitos ahorros

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.28657	0.28657	11	-0.04112	-0.00241
2	0.07665	-0.00596	12	-0.09836	-0.14518
3	-0.11434	-0.14679	13	-0.11723	-0.12221
4	-0.06131	0.01206	14	-0.09084	-0.07320
5	-0.09459	-0.07205	15	-0.10831	-0.15714
6	-0.05891	-0.03212	16	-0.11473	-0.16001
7	-0.07177	-0.04911	17	-0.08980	-0.14893
8	-0.08145	-0.07165	18	-0.05008	-0.16618
9	-0.14486	-0.12457	19	0.15832	0.05310
10	-0.12405	-0.07596			

Tabla 4.30: Autocorrelación y Autocorrelación Parcial: Serie depósitos ahorros




Figura 4.14: Serie logaritmo depósitos ahorros

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.35168	0.35168	11	-0.02681	0.01659
2	0.09855	-0.02868	12	-0.12295	-0.21578
3	-0.12698	-0.17422	13	-0.10635	-0.00956
4	-0.03629	0.07879	14	-0.09287	-0.02783
5	-0.03352	-0.02824	15	-0.09962	-0.14661
6	0.00071	-0.01221	16	-0.13758	-0.09993
7	-0.01000	0.00147	17	-0.12008	-0.07317
8	-0.05538	-0.06824	18	-0.04419	-0.07229
9	-0.18990	-0.17526	19	0.05308	0.03647
10	-0.10556	0.03197			

Tabla 4.31: Autocorrelación y Autocorrelación Parcial: Logaritmo ahorros

4.4.1. MODELO ARMA: LOGARITMO AHORROS

En el **Anexo A** se describen los modelos de series de tiempo que no fueron seleccionados tanto para la serie original como para la serie logarítmica de depósitos de ahorros. En este sentido, a continuación se presenta únicamente el modelo $\text{arima}(2,0,0)(1,1,0)$ que fue seleccionado para la serie logarítmica de depósitos de ahorros:

```
> ar.ahorros<-Arima(log(ts.ahorros),
+                   order=c(2,0,0), seasonal=list(order=c(1,1,0)),
+                   include.mean=FALSE, include.constant=FALSE)
> resid.ahorros<-ar.ahorros$residuals
> residscr.ahorros<-resid.ahorros*resid.ahorros
```

```
Series: log(ts.ahorros) ARIMA(2,0,0)
```

```
Coefficients:
```

```
          ar1      ar2      sar1
          0.341  -0.4614  -0.7027
s.e.      0.112   0.1057   0.0934
sigma^2 estimated as 0.248: log likelihood=-64.46
AIC=136.92  AICc=137.39  BIC=146.87
```

4.4.2. PRUEBA ESTADÍSTICA DE BOX PIERCE - LJUNG BOX

Una vez que se ha definido el modelo que se aplicará a la serie logarítmica de depósitos de ahorros, se efectúa la prueba estadística de Box Pierce - Ljung Box, con el fin de examinar la siguiente prueba de hipótesis:

H0: Las observaciones son independientes.

H1: Las observaciones no son independientes.

Si $\{p - \text{valor} < \alpha\}$ se rechaza la hipótesis nula, para $\alpha = 0.05$. En las tablas 4.32, 4.33 y 4.34, se presenta los resultados de la prueba de Box Pierce - Ljung Box, que se aplicó tanto a la serie logarítmica como a los residuos y a los residuos al cuadrado del modelo $\text{arima}(2,0,0)(1,1,0)$.

Retardo	p-valor	Retardo	p-valor
1	0.0025	11	0.0743
2	0.0037	12	0.0801
3	0.0088	13	0.0911
4	0.0178	14	0.0996
5	0.0335	15	0.0890
6	0.0571	16	0.0877
7	0.0828	17	0.1118
8	0.0456	18	0.1372
9	0.0515	19	0.1166
10	0.0754		

Tabla 4.32: Prueba de Box Pierce - Ljung Box: Log. depósitos ahorros

Retardo	p-valor	Retardo	p-valor
1	0.9257	11	0.8615
2	0.3411	12	0.8847
3	0.4914	13	0.9184
4	0.6269	14	0.9409
5	0.7460	15	0.9533
6	0.8357	16	0.9579
7	0.8968	17	0.9628
8	0.7658	18	0.9708
9	0.8163	19	0.9729
10	0.8525		

Tabla 4.33: Prueba de Box Pierce - Ljung Box: Residuos depósitos ahorros

Retardo	p-valor	Retardo	p-valor
1	0.0115	11	0.0325
2	0.0114	12	0.0319
3	0.0159	13	0.0270
4	0.0194	14	0.0256
5	0.0206	15	0.0307
6	0.0215	16	0.0401
7	0.0202	17	0.0487
8	0.0220	18	0.0367
9	0.0294	19	0.0303
10	0.0345		

Tabla 4.34: Prueba de Box Pierce - Ljung Box: Residuos al cuadrado dep. ahorros

Al aplicar la prueba de Box Pierce - Ljung Box, se determinó que tanto la serie logarítmica como la serie de los residuos al cuadrado del modelo $\text{arima}(2,0,0)(1,1,0)$, el p-valor de cada uno de los retardos es inferior a $\alpha = 0.05$; consecuentemente, tanto la serie logarítmica de los depósitos de ahorros como los residuos al cuadrado del modelo $\text{arima}(2,0,0)(1,1,0)$ no son independientes dado que se rechaza la hipótesis nula, únicamente para la serie de los residuos del modelo $\text{arima}(2,0,0)(1,1,0)$, el p-valor de cada uno de los retardos es superior a $\alpha = 0.05$; consecuentemente, la serie de los residuos del modelo $\text{arima}(2,0,0)(1,1,0)$ son independientes dado que no se rechaza la hipótesis nula.

4.4.3. AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO ARIMA

Se verifica la existencia de autocorrelación y autocorrelación parcial, a través del gráfico y la respectiva tabla de los residuos y de los residuos al cuadrado del modelo $\text{arima}(2,0,0)(1,1,0)$ de la serie de depósitos de ahorros:




Figura 4.15: Gráfico de los residuos del modelo $\text{arima}(2,0,0)(1,1,0)$

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.02611	0.02611	11	0.05932	0.06767
2	0.03243	0.03177	12	-0.08480	-0.15769
3	-0.18941	-0.19139	13	-0.06558	-0.08004
4	0.02686	0.03807	14	-0.02816	0.00691
5	-0.02704	-0.01682	15	-0.04040	-0.10849
6	0.00951	-0.02861	16	-0.05882	-0.09258
7	-0.01080	0.00396	17	-0.07675	-0.08794
8	-0.01995	-0.02965	18	-0.07439	-0.15790
9	-0.15750	-0.16426	19	-0.05717	-0.12990
10	-0.05299	-0.04425			

Tabla 4.35: Autocorrelación y Autocorrelación Parcial: Residuos

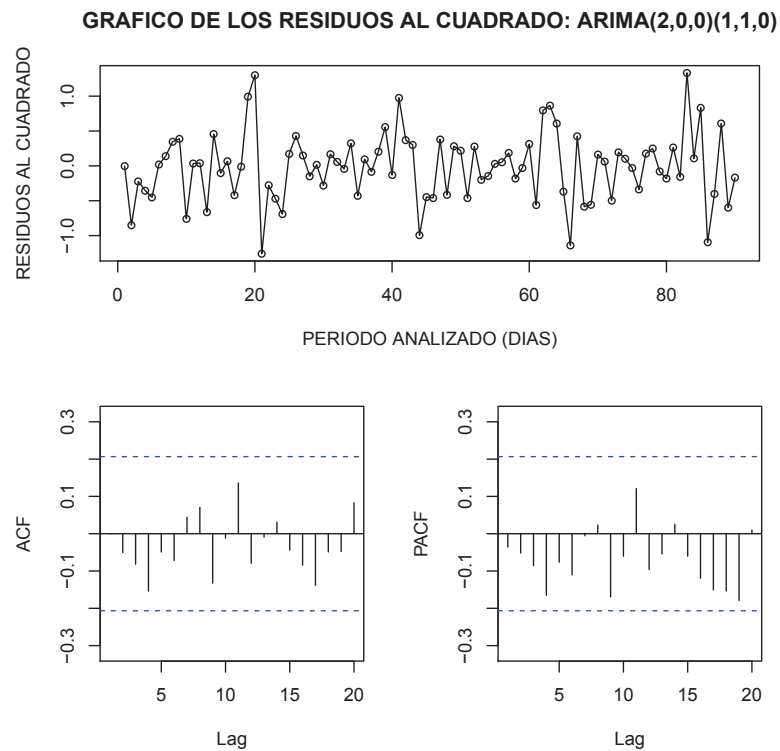


Figura 4.16: Gráfico de los residuos al cuadrado del modelo arima(2,0,0)(1,1,0)

Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.25830	0.25830	11	-0.10137	-0.07029
2	0.18337	0.12499	12	-0.13338	-0.12697
3	0.15444	0.08786	13	-0.12722	-0.11446
4	-0.11345	-0.20692	14	-0.14766	-0.12143
5	-0.11905	-0.09513	15	-0.13198	-0.10098
6	-0.12982	-0.06064	16	-0.08824	-0.08854
7	-0.12820	-0.01233	17	-0.06129	-0.09464
8	-0.13873	-0.08265	18	-0.07736	-0.16349
9	-0.11929	-0.06858	19	0.16448	0.12120
10	-0.08061	-0.03804			

Tabla 4.36: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado

4.4.4. PRUEBAS DE NORMALIDAD DE LOS ERRORES

Con esta prueba se requiere verificar si los residuos siguen una distribución normal, planteándose la siguiente hipótesis:

Ho: Los residuos siguen una distribución $N(\mu, \sigma)$

Ha: Los residuos no siguen una distribución $N(\mu, \sigma)$

Para el efecto, se calcularon tres pruebas estadísticas que permitan confirmar o negar la hipótesis nula: la prueba de Shapiro-Wilk, la prueba de Kolmogorov Smirnov (KS) y la prueba de Anderson Darling (AD),

Shapiro-Wilk: $W = 0.9847$, p-valor = 0.3745.

Kolmogorov-Smirnov: $D = 0.0613$, p-valor = 0.8665.

Anderson-Darling: $AD = 0.4504$, p-valor = 0.7973.

Se concluye que para el caso de las tres pruebas de normalidad aplicadas los valores críticos son superiores a $\alpha = 0.05$; por lo tanto, los residuos siguen una distribución $N(\mu, \sigma)$ dado que no se rechaza la hipótesis nula.

Adicionalmente, se presenta el histograma y el gráfico de cuantiles de los residuales:

```
> par(mfrow=c(1,2))
> hist(resid.ahorros,main="HISTOGRAMA",
```

```

+       xlab="RESIDUOS",ylab="FRECUENCIA",cex=0.95)
> qqnorm(resid.ahorros,main="GRAFICO Q-Q",
+       xlab="CUANTILES TEORICOS",
+       ylab="MUESTRA DE LOS CUANTILES",cex=0.95)
> qqline(resid.ahorros)

```

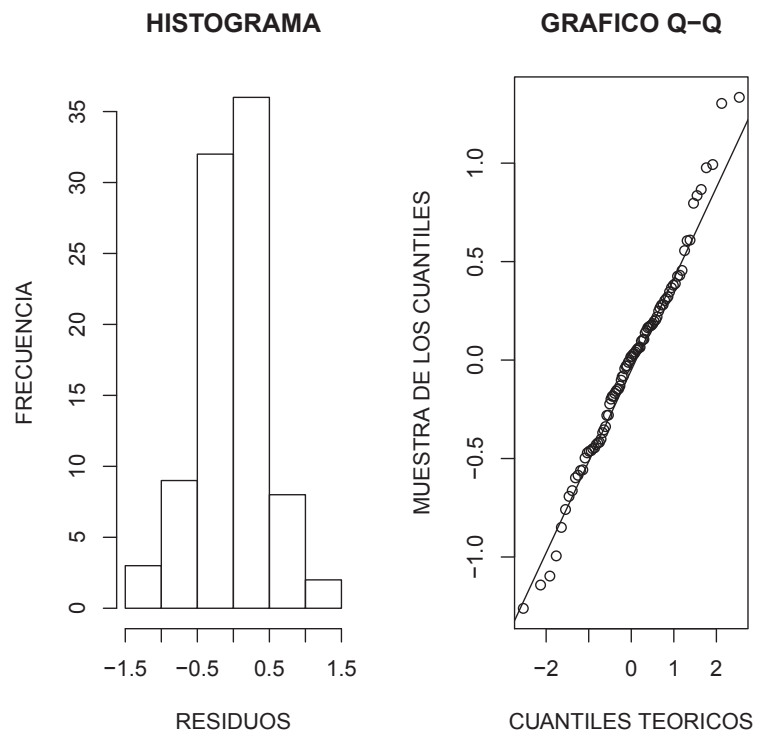


Figura 4.17: Histograma de residuales y Gráfico Q-Q de residuales

4.4.5. MODELO GARCH PARA LA VARIANZA CONDICIONAL: LOGARITMO DE LA SERIE DEPÓSITOS AHORROS

Considerando que al efectuar la prueba de Box Pierce - Ljung Box resultó que las observaciones de los retardos de la serie logarítmica y de residuos al cuadrado no son independientes dado que no se rechazó la hipótesis nula; con el fin de corregir estas distorsiones en los residuos al cuadrado, se aplicó un modelo GARCH(1,1) para la varianza condicional:

```
> garch.ahorros<-garch(resid.ahorros,order = c(1, 1),
+ control = garch.control(trace=TRUE, start=NULL))
> resid.ahorros2<-garch.ahorros$residuals[-1]
> residsq.ahorros2<-resid.ahorros2*resid.ahorros2
```

```
Call: garch(x=resid.ahorros, order=c(1, 1),
control=garch.control(trace =TRUE,start=NULL))
Model: GARCH(1,1)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-2.24407	-0.70958	0.04183	0.59256	3.31089

Coefficient(s):

	Estimate	Std. Error	t value	Pr(> t)
a0	0.08596	0.06845	1.256	0.209
a1	0.23362	0.17128	1.364	0.173
b1	0.41720	0.39668	1.052	0.293

Jarque Bera Test

X-squared = 4.044, df = 2, p-value = 0.1324

Box-Ljung test

X-squared = 0.0047, df = 1, p-value = 0.9451

4.4.6. PRUEBA DE BOX PIERCE - LJUNG BOX PARA LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO GARCH

Una vez que se ha definido el modelo GARCH que se aplicará para la varianza condicional, se efectúa la prueba estadística de Box Pierce - Ljung Box, con el fin de examinar la prueba de hipótesis para los residuos y los residuos al cuadrado del modelo GARCH de la varianza condicional:

H0: Las observaciones son independientes.

H1: Las observaciones no son independientes.

Si $\{p - \text{valor} < \alpha\}$ se rechaza la hipótesis nula, para $\alpha = 0.05$. En las tablas C.6 y 4.38, se presenta los resultados de la prueba de Box Pierce - Ljung Box, que se aplicó a los residuos y a los residuos al cuadrado del modelo GARCH(1,1).

Retardo	p-valor	Retardo	p-valor
1	0.9061	11	0.7008
2	0.8104	12	0.7706
3	0.5877	13	0.8276
4	0.7203	14	0.8721
5	0.6974	15	0.8742
6	0.7563	16	0.7735
7	0.7817	17	0.8171
8	0.6305	18	0.8583
9	0.7190	19	0.8669
10	0.6826		

Tabla 4.37: Prueba de Box Pierce - Ljung Box: Residuos del modelo GARCH de ahorros

Retardo	p-valor	Retardo	p-valor
1	0.8813	11	0.7219
2	0.5611	12	0.6028
3	0.5839	13	0.6293
4	0.7034	14	0.6873
5	0.8018	15	0.6675
6	0.8113	16	0.4940
7	0.7250	17	0.5629
8	0.7313	18	0.6227
9	0.7766	19	0.5203
10	0.8407		

Tabla 4.38: Prueba de Box Pierce - Ljung Box: Residuos al cuadrado del modelo GARCH de ahorros

Al aplicar la prueba de Box Pierce - Ljung Box, se determinó que tanto la serie de los residuos como la serie de los residuos al cuadrado del modelo GARCH(1,1), el p-valor de cada uno de los retardos es superior a $\alpha = 0.05$; consecuentemente, tanto los residuos como los residuos al cuadrado del modelo GARCH(1,1) son independientes dado que no se rechaza la hipótesis nula.

4.4.7. AUTOCORRELACIÓN EN LOS RESIDUOS Y RESIDUOS AL CUADRADO DEL MODELO GARCH

Se verifica la existencia de autocorrelación y autocorrelación parcial, a través del gráfico y la respectiva tabla de los residuos y de los residuos al cuadrado del modelo GARCH(1,1) de la serie de depósitos de ahorros:




Figura 4.18: Gráfico de los residuos del modelo GARCH(1,1)

Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.04697	-0.04697	11	0.11953	0.14180
2	-0.00309	-0.00531	12	-0.08775	-0.11474
3	-0.09270	-0.09331	13	0.00858	-0.04634
4	-0.14464	-0.15517	14	0.01583	0.05005
5	-0.02232	-0.04139	15	-0.02344	-0.06598
6	-0.10488	-0.12499	16	-0.09186	-0.12797
7	0.06313	0.01826	17	-0.17008	-0.14422
8	0.07998	0.05436	18	-0.03820	-0.15220
9	-0.16049	-0.19310	19	-0.02245	-0.11736
10	0.00708	-0.04267			

Tabla 4.39: Autocorrelación y Autocorrelación Parcial: Residuos

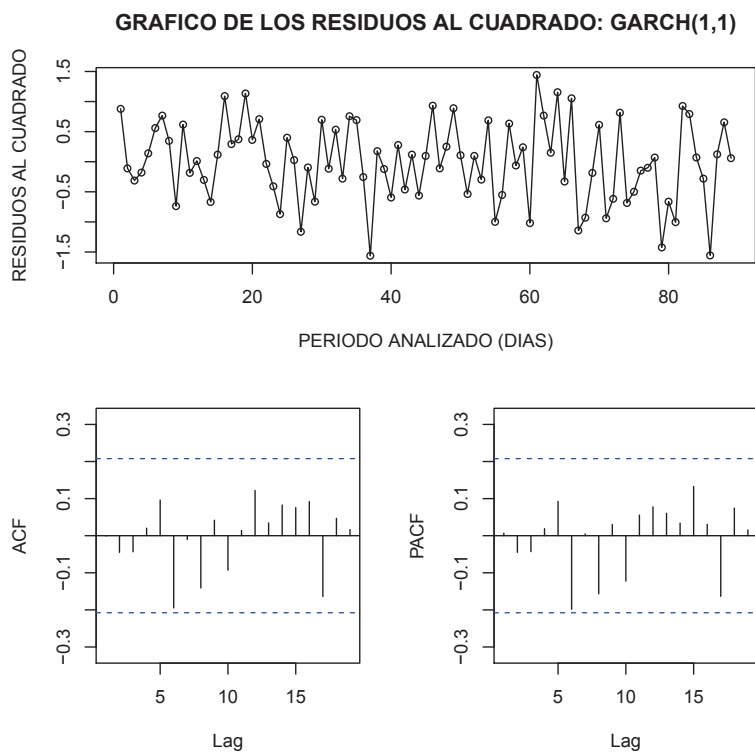


Figura 4.19: Gráfico de los residuos al cuadrado del modelo GARCH(1,1)

Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.00718	-0.00718	11	-0.01473	0.01372
2	0.05281	0.05276	12	-0.16120	-0.17393
3	0.14229	0.14344	13	-0.16143	-0.20998
4	-0.09429	-0.09630	14	-0.08330	-0.13527
5	-0.03847	-0.05694	15	-0.04465	-0.04137
6	-0.02957	-0.04096	16	-0.11522	-0.17325
7	-0.08644	-0.05603	17	0.19406	0.11401
8	-0.13323	-0.13061	18	-0.00267	-0.06495
9	-0.09396	-0.09287	19	0.03174	-0.03042
10	-0.06348	-0.04363			

Tabla 4.40: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado

4.4.8. PRUEBAS DE NORMALIDAD DE LOS ERRORES DEL MODELO GARCH(1,1) DE LA SERIE DEPÓSITOS DE AHORROS

Con esta prueba se requiere verificar si los residuos del modelo GARCH(1,1) siguen una distribución normal, planteándose la siguiente hipótesis:

H₀: Los residuos siguen una distribución $N(\mu, \sigma)$

H_a: Los residuos no siguen una distribución $N(\mu, \sigma)$

Para el efecto, se calcularon tres pruebas estadísticas que permitan confirmar o negar la hipótesis nula: la prueba de Shapiro-Wilk, la prueba de Kolmogorov Smirnov (KS) y la prueba de Anderson Darling (AD),

Shapiro-Wilk: $W = 0.9821$, p-valor = 0.2581.

Kolmogorov-Smirnov: $D = 0.0665$, p-valor = 0.8012.

Anderson-Darling: $AD = 0.3657$, p-valor = 0.8816.

Se concluye que para el caso de las tres pruebas de normalidad aplicadas los valores críticos son superiores a $\alpha = 0.05$; por lo tanto, los residuos siguen una distribución $N(\mu, \sigma)$ dado que no se rechaza la hipótesis nula.

Adicionalmente, se presenta el histograma y el gráfico de cuantiles de los residuales:

```
> par(mfrow=c(1,2))
```

```

> hist(resid.ahorros2,main="HISTOGRAMA",
+      xlab="RESIDUOS",ylab="FRECUENCIA",cex=0.95)
> qqnorm(resid.ahorros2,main="GRAFICO Q-Q",
+        xlab="CUANTILES TEORICOS",
+        ylab="MUESTRA DE LOS CUANTILES",cex=0.95)
> qqline(resid.ahorros2)

```

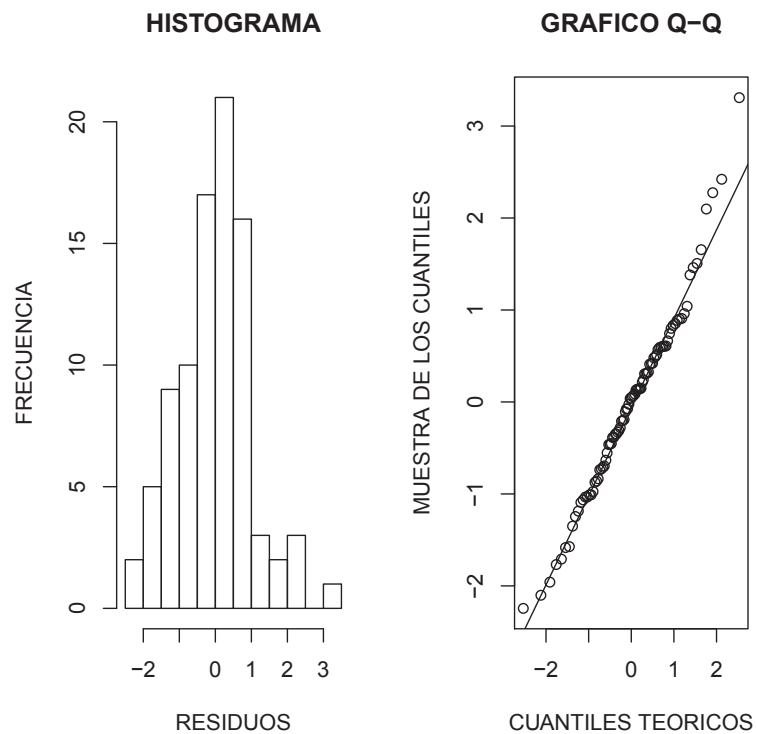


Figura 4.20: Histograma y Gráfico Q-Q de residuales modelo GARCH(1,1)

4.4.9. SELECCIÓN DEL MEJOR MODELO: DEPÓSITOS A PLAZO

Se seleccionó el mejor modelo en función de las siguientes consideraciones:

- acf y pacf de residuos están dentro de las bandas, por lo tanto, no presentan autocorrelación.
- acf y pacf de residuos al cuadrado están dentro de las bandas, por lo tanto, no presentan autocorrelación.

- A través de la prueba box.test se acepta H_0 : Los residuos son independientes.
- A través de la prueba box.test se acepta H_0 : Los residuos al cuadrado son independientes.
- El p-value de shapiro.test >0.05 por lo tanto los residuos se ajustan a una distribución normal.
- El p-value del test KS >0.05 por lo tanto los residuos se ajustan a una distribución normal.
- El p-value del test AD >0.05 por lo tanto los residuos se ajustan a una distribución normal.

4.4.10. PREDICCIÓN DE LA SERIE DEPÓSITOS AHORROS

Las ecuaciones (4.3) y (4.4) permiten predecir el logaritmo de la variación de los depósitos ahorros en el tiempo (t):

$$x_t = 0.6383 * x_{t-1} + 0.1399 * x_{t-2} - 0.1024 * x_{t-3} + 0.3242 * x_{t-4} + e_t \quad (4.3)$$

$$e_t = \sqrt{0.08105 + 0.24992 * e_{t-1}^2 + 0.4164 * \frac{e_{t-1}^2}{\mu_{t-1}^2}} * \mu_t \quad (4.4)$$

Donde:

x_t → logaritmo de la serie depósitos ahorros en el tiempo (t)

x_{t-1} → logaritmo de la serie depósitos ahorros con un retardo (t-1)

x_{t-2} → logaritmo de la serie depósitos ahorros con dos retardos (t-2)

x_{t-3} → logaritmo de la serie depósitos ahorros con tres retardos (t-3)

x_{t-4} → logaritmo de la serie depósitos ahorros con cuatro retardos (t-4)

e_t → residuos del modelo ARIMA(2,0,0)(1,1,0)

e_{t-1}^2 → residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0) con un retardo (t-1)

μ_t → residuos del modelo GARCH(1,1)

$\mu_{t-1}^2 \rightarrow$ residuos al cuadrado del modelo GARCH(1,1) con un retardo (t-1)

Para $t = 1, 2, 3, 4, 5, \dots$, 91 días de cálculo.

La implementación de la ecuación antes descrita es:

```
> predahorros<-matrix(nrow=85,ncol=1)

> x<-log(ts.ahorros)[-1]

> e<-resid.ahorros[-1]

> e2<-residsqr.ahorros[-1]

> u<-resid.ahorros2

> u2<-residsqr.ahorros2

> for (i in 1:85)

+ {predahorros[i]<-0.6383*x[i+3] + 0.1399*x[i+2] -
+ 0.1024*x[i+1]+0.3242*x[i]+(sqrt(0.08105+0.24992*e2[i+3] +
+ 0.4164*(e2[i+3]/u2[i+3])))*u[i+4])}

> ts.predahorros<-ts(predahorros)
```

En el gráfico 4.21 , se presentan los datos pronosticados versus los datos reales del logaritmo de la variación lineal de la serie depósitos ahorros.

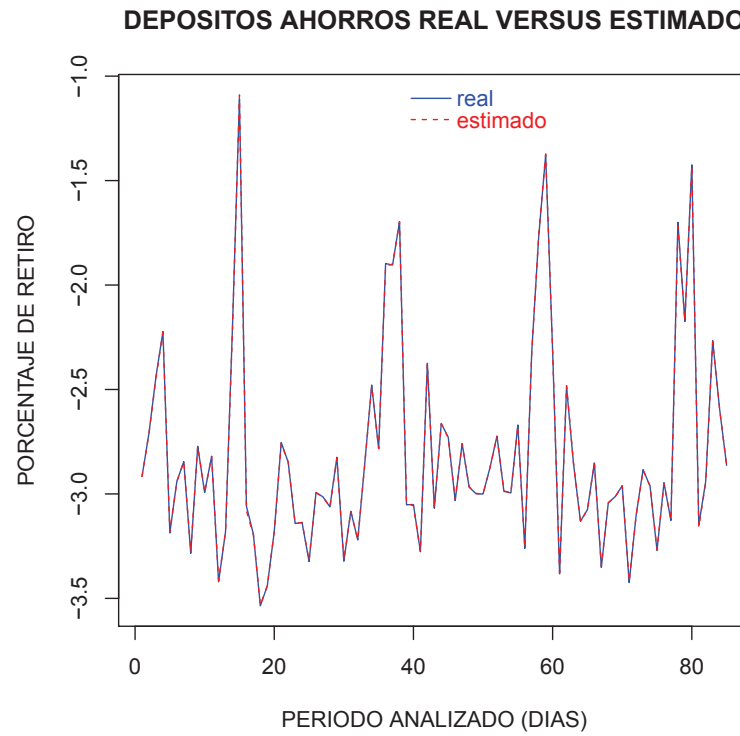


Figura 4.21: Predicción serie depósitos ahorros

Capítulo 5

MODELO DE DEPENDENCIA NO LINEAL

Las variables sobre las cuales se probará si existe o no dependencia no lineal, corresponden a los residuos de cada uno de los modelos de series de tiempo resultantes, para cada fuente de fondeo analizada: depósitos corriente, depósitos a plazo y depósitos de ahorros, a continuación se detalla la notación que se utilizará en el modelo de dependencia no lineal:

x1 → residuos del modelo arma(1,0) de la serie depósitos corriente, que corresponden a la ecuación (5.1):

$$x_t = -1.4558 + 0.2140 * x_{t-1} + \mu_t \quad (5.1)$$

x2 → residuos del modelo arma(1,0) de la serie depósitos a plazo, que corresponde a las ecuación (5.2).

$$x_t = -4.16468 - 0.03156 * x_{t-1} + \mu_t \quad (5.2)$$

x3 → residuos del modelo arima(2,0,0)(1,1,0) GARCH(1,1) de la serie depósitos de ahorros, que corresponden a las ecuaciones (5.3) y (5.4).

$$x_t = 0.6383 * x_{t-1} + 0.1399 * x_{t-2} - 0.1024 * x_{t-3} + 0.3242 * x_{t-4} + e_t \quad (5.3)$$

$$e_t = \sqrt{0.08105 + 0.24992 * e_{t-1}^2 + 0.4164 * \frac{e_{t-1}^2}{\mu_{t-1}^2}} * \mu_t \quad (5.4)$$

Es importante considerar que previamente en el capítulo anterior, se modeló la autocorrelación de las variables (X1, X2, X3).

5.1. PRUEBAS DE BONDAD DE AJUSTE

5.1.1. PRUEBAS DE BONDAD DE AJUSTE DE LAS MARGINALES

Se realizan las pruebas de bondad de ajuste de las marginales, en este caso de las variables (x_1 , x_2 , x_3), a través de las pruebas de Kolmogorov - Smirnov y Anderson - Darling. Se plantea la siguiente prueba de hipótesis:

Ho: Los residuos x_i siguen una distribución $N(\mu, \sigma)$

Ha: Los residuos x_i no siguen una distribución $N(\mu, \sigma)$

Para $i=1,2,3$

```
> y1<-fitdistr(x1, "normal")$estimate
> ksy1<-ks.test(x1, pnorm, mean=y1[1], sd=y1[2])
> ady1<-ad.test(x1, pnorm, mean=y1[1], sd=y1[2])

> y2<-fitdistr(x2, "normal")$estimate
> ksy2<-ks.test(x2, pnorm, mean=y2[1], sd=y2[2])
> ady2<-ad.test(x2, pnorm, mean=y2[1], sd=y2[2])

> y3<-fitdistr(x3, "normal")$estimate
> ksy3<-ks.test(x3, pnorm, mean=y3[1], sd=y3[2])
> ady3<-ad.test(x3, pnorm, mean=y3[1], sd=y3[2])
```

Residuos	P-valor KS	P-valor AD	Prueba de Hipótesis
Corriente (x_1)	0.2663	0.4366	sigue una distribución $N(\mu, \sigma)$
Plazo (x_2)	0.7452	0.9179	sigue una distribución $N(\mu, \sigma)$
Ahorros (x_3)	0.8757	0.8267	sigue una distribución $N(\mu, \sigma)$

Tabla 5.1: Pruebas de bondad de ajuste de las marginales

Dado que los valores críticos de las pruebas de Kolmogorov - Smirnov y Anderson - Darling de las variables (x_1 , x_2 , x_3) son superiores a $\alpha = 0.05$, no se rechaza la hipótesis nula; por lo tanto, los residuos siguen una distribución $N(\mu, \sigma)$.

5.1.2. PRUEBAS DE AJUSTE SOBRE LAS FUNCIONES DE CADA RESIDUO

Con el fin de obtener el vector de probabilidades, se evaluó la función de distribución $N(\mu, \sigma)$ de cada uno de los residuos, los cuales constituyen los fractiles de la distribución.

A continuación, se describe las rutinas de cálculo que se utilizaron para estimar el vector de probabilidades de cada uno de los residuos (x_1, x_2, x_3).

- Algoritmo para calcular las probabilidades de los residuos (x_1) que corresponden al modelo arma(1,0) de la serie depósitos corriente:

```
> px1 <- pnorm(x1, mean = y1[1], sd = y1[2],
+             lower.tail = TRUE, log.p = FALSE)
```

- Algoritmo para calcular las probabilidades de los residuos (x_2) que corresponden al modelo arma(1,0) de la serie depósitos a plazo:

```
> px2 <- pnorm(x2, mean = y2[1], sd = y2[2],
+             lower.tail = TRUE, log.p = FALSE)
```

- Algoritmo para calcular las probabilidades de los residuos (x_3) que corresponden al modelo arima(2,0,0)(1,1,0) GARCH(1,1) de la serie depósitos de ahorros:

```
> px3 <- pnorm(x3, mean = y3[1], sd = y3[2],
+             lower.tail = TRUE, log.p = FALSE)
```

En la tabla 5.2 , se presenta un resumen de los mínimos y máximos que se estimó para el vector de probabilidades (x_1, x_2, x_3), respectivamente; a través de la función de distribución normal $N(\mu, \sigma)$.

Residuos	Min	Max
Prob.corriente (px1)	0.0219	0.9946
Prob.plazo (px2)	0.0091	0.9854
Prob.ahorros (px3)	0.0063	0.9967

Tabla 5.2: Mínimos y máximos de las probabilidades de los residuos

5.1.3. PRUEBAS DE AJUSTE DE LAS PROBABILIDADES A UNA DISTRIBUCIÓN UNIFORME

A través de las pruebas de Kolmogorov - Smirnov y Anderson - Darling, se realiza la siguiente prueba de hipótesis:

H₀: Las probabilidades de los residuos (x_1, x_2, x_3) siguen una distribución uniforme $U(0, 1)$

H_a: Las probabilidades de los residuos (x_1, x_2, x_3) no siguen una distribución uniforme $U(0, 1)$

```
> ksy5<-ks.test(px1, punif, 0, 1)
> ady5<-ad.test(px1, punif, 0, 1)
> ksy6<-ks.test(px2, punif, 0, 1)
> ady6<-ad.test(px2, punif, 0, 1)
> ksy7<-ks.test(px3, punif, 0, 1)
> ady7<-ad.test(px3, punif, 0, 1)
```

Residuos	P-valor KS	P-valor AD	Prueba de Hipótesis
Prob.corriente (px1)	0.2663	0.4366	sigue una distribución $U(0, 1)$
Prob.plazo (px2)	0.7452	0.9179	sigue una distribución $U(0, 1)$
Prob.ahorros (px3)	0.8757	0.8267	sigue una distribución $U(0, 1)$

Tabla 5.3: Pruebas de ajuste de las probabilidades a una distribución uniforme

Dado que los valores críticos de las pruebas de Kolmogorov - Smirnov y Anderson - Darling son superiores a $\alpha = 0.05$, no se rechaza la hipótesis nula; por lo tanto, las probabilidades de los residuos x_1, x_2, x_3 siguen una distribución uniforme $U(0, 1)$.

5.2. PRUEBAS DE INDEPENDENCIA

Pruebas de independencia en conjunto (px1, px2, px3)

Se realizan pruebas de independencia sobre las variables px_1, px_2, px_3 , que representan a las probabilidades que se ajustaron a una distribución unifor-

me de los residuos x_1 , x_2 , x_3 , respectivamente; a través de la siguiente prueba de hipótesis:

H₀: Se plantea que las variables px_1 , px_2 , px_3 son independientes

H_a: Se plantea que las variables px_1 , px_2 , px_3 no son independientes

```
> prueba1.paso1 <- indepTestSim(n=89, p=3, N = 1000)
> prueba1.paso2 <- indepTest(cbind(px1,px2,px3),
+                             prueba1.paso1, alpha=0.05)
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.0004995005
- Estadístico de Cramer-von Mises = 0.1803713

Dado que el valor crítico de esta prueba es menor al estadístico de Cramer-von Mises, se rechaza la hipótesis nula; es decir, las probabilidades px_1 , px_2 , px_3 no son independientes.

Pruebas de independencia por pares (px_1 , px_2)

Se plantea la siguiente prueba de hipótesis:

H₀: Se plantea que las variables px_1 , px_2 son independientes

H_a: Se plantea que las variables px_1 , px_2 no son independientes

```
> prueba2.paso1 <- indepTestSim(n=89, p=2, N = 1000)
> prueba2.paso2 <- indepTest(cbind(px1,px2),
+                             prueba2.paso1, alpha=0.05)
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.1293706
- Estadístico de Cramer-von Mises = 0.04210949

Dado que el valor crítico de esta prueba es mayor al estadístico de Cramer-von Mises, no se rechaza la hipótesis nula; es decir, las probabilidades px_1 , px_2 son independientes.

Pruebas de independencia por pares (px_1 , px_3)

Se plantea la siguiente prueba de hipótesis:

Ho: Se plantea que las variables px_1 , px_3 son independientes

Ha: Se plantea que las variables px_1 , px_3 no son independientes

```
> prueba3.paso1 <- indepTestSim(n=89, p=2, N = 1000)
> prueba3.paso2 <- indepTest(cbind(px1, px3),
+                             prueba3.paso1, alpha=0.05)
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.0004995005
- Estadístico de Cramer-von Mises = 0.2205508

Dado que el valor crítico de esta prueba es menor al estadístico de Cramer-von Mises, se rechaza la hipótesis nula; es decir, las probabilidades px_1 , px_3 no son independientes.

Pruebas de independencia por pares (px_2 , px_3)

Se plantea la siguiente prueba de hipótesis:

Ho: Se plantea que las variables px_2 , px_3 son independientes

Ha: Se plantea que las variables px_2 , px_3 no son independientes

```
> prueba4.paso1 <- indepTestSim(n=89, p=2, N = 1000)
> prueba4.paso2 <- indepTest(cbind(px2, px3),
+                             prueba4.paso1, alpha=0.05)
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.005494505
- Estadístico de Cramer-von Mises = 0.08487854

Dado que el valor crítico de esta prueba es menor al estadístico de Cramer-von Mises, se rechaza la hipótesis nula; es decir, las probabilidades p_{x2} , p_{x3} no son independientes.

Resumen de las pruebas de independencia en conjunto y por pares

Prueba Indep.	Cramer-von Mises	P-Valor	Prueba de Hipótesis
(p_{X1}, p_{X2}, p_{X3})	0.18037	0.0004995005	no son independientes
(p_{X1}, p_{X2})	0.04211	0.1293706	son independientes
(p_{X1}, p_{X3})	0.22055	0.0004995005	no son independientes
(p_{X2}, p_{X3})	0.08488	0.005494505	no son independientes

Tabla 5.4: Resumen pruebas de independencia

Considerando que únicamente las probabilidades de los residuos constituidos por la dupla (p_{x1} , p_{x2}) son independientes dado que no se rechazó la hipótesis nula, es necesario modelar la dependencia no lineal de las probabilidades p_{x1} , p_{x2} , p_{x3} , correspondientes a los residuos de las fuentes de fondeo analizadas: depósitos corriente, depósitos a plazo y depósitos de ahorros; a través de la técnica estadística de las **Cópulas**.

5.3. PRUEBAS DE BONDAD DE AJUSTE: CÓPULAS ARQUIMEDIANAS

Se realizan pruebas de bondad de ajuste a las probabilidades p_{x1} , p_{x2} , p_{x3} , a través de la prueba de hipótesis nula que las probabilidades de los residuos se ajustan a alguna de las cópulas Arquimedianas: Gumbel, Clayton o Frank.

En el software **R** existen 2 tipos de funciones que permiten realizar ajustes a una cópula Arquimediana; en este sentido, se presentan las rutinas de cálculo de los dos tipos de métodos.

Cópula Gumbel

Se plantea la siguiente prueba de hipótesis:

H₀: Las probabilidades de los residuos (px1, px2, px3) se ajustan a la Cópula de Gumbel

H_a: Las probabilidades de los residuos (px1, px2, px3) no se ajustan a la Cópula de Gumbel

Método 1

```
> prueba1.ajuste <- gofCopula(gumbelCopula(param=NA_real_,
>                               dim=3), cbind(px1,px2,px3))
```

Método 2

```
> prueba6.ajuste <-gofCopula(archmCopula("gumbel",
>                                     param=1, dim=3,
>                                     dispstr = "un"),
>                               cbind(px1,px2,px3),N=1000)
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.2942
- Estadístico de Cramer-von Mises = 0.0367
- Parámetro estimado = 1.306

Dado que el valor crítico de esta prueba es mayor al estadístico de Cramer-von Mises, no se rechaza la hipótesis nula; es decir, las probabilidades de los residuos (px1, px2, px3) se ajustan a la cópula de Gumbel.

Cópula de Clayton

Se plantea la siguiente prueba de hipótesis:

H₀: Las probabilidades de los residuos (px1, px2, px3) se ajustan a la Cópula de Clayton

H_a: Las probabilidades de los residuos (px1, px2, px3) no se ajustan a la Cópula de Clayton

Método 2

```
> prueba5.ajuste <- gofCopula(archmCopula("frank",
>                               param=1, dim=3,
>                               dispstr = "un"),
>                               cbind(px1,px2,px3),N=500)
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.1024
- Estadístico de Cramer-von Mises = 0.0516
- Parámetro estimado = 2.155

Dado que el valor crítico de esta prueba es mayor al estadístico de Cramer-von Mises, no se rechaza la hipótesis nula; es decir, las probabilidades de los residuos (px1, px2, px3) se ajustan a la cópula de Frank.

Resumen de las cópulas ARQUIMEDIANAS

En la tabla 5.5, se muestra para cada método de las cópulas Arquimedianas un resumen del estadístico de Cramer-von Mises, valores críticos y el resultado de la prueba de hipótesis.

Prueba Ajuste	Cramer-von Mises	P-Valor	Prueba de Hipótesis
Gumbel	0.0367	0.2942	se ajusta
Clayton	0.1048	0.002498	no se ajusta
Frank	0.0516	0.1024	se ajusta

Tabla 5.5: Resumen cópulas ARQUIMEDIANAS

5.4. PRUEBAS DE BONDAD DE AJUSTE: CÓPULAS ELÍPTICAS

Se realizan pruebas de bondad de ajuste a las probabilidades px1, px2, px3, a través de la prueba de hipótesis nula que las probabilidades de los residuos se ajustan a alguna de las cópulas Elípticas: Normal o t.

Al igual que en las cópulas Arquimedianas, para el caso de las cópulas Elípticas se utilizarán las rutinas de cálculo de los dos tipos de métodos que tiene el software **R** para realizar ajustes a una cópula.

Cópula Normal

Se plantea la siguiente prueba de hipótesis:

Ho: Las probabilidades de los residuos (px1, px2, px3) se ajustan a la Cópula Normal

Ha: Las probabilidades de los residuos (px1, px2, px3) no se ajustan a la Cópula Normal

Método 1

```
prueba7.ajuste <- gofCopula(normalCopula(c(0.5, 0.5, 0.5),
dim = 3, dispstr = "un"),
cbind(px1,px2,px3))
```

Método 2

```
prueba9.ajuste <- gofCopula(ellipCopula("normal",
c(0.5, 0.5, 0.5),
dim = 3, dispstr = "un"),
cbind(px1,px2,px3),N=500)
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.2485
- Estadístico de Cramer-von Mises = 0.0334
- Parámetros estimados = (0.215, 0.556, 0.316)

Dado que el valor crítico de esta prueba es mayor al estadístico de Cramer-von Mises, no se rechaza la hipótesis nula; es decir, las probabilidades de los residuos (px1, px2, px3) se ajustan a la cópula Normal.

Cópula t

Se plantea la siguiente prueba de hipótesis:

Ho: Las probabilidades de los residuos (px_1 , px_2 , px_3) se ajustan a la Cópula t

Ha: Las probabilidades de los residuos (px_1 , px_2 , px_3) no se ajustan a la Cópula t

Método 1

```
prueba8.ajuste <- gofCopula(tCopula(c(0.5, 0.5, 0.5),
  dim = 3, dispstr = "un",
  df.fixed=TRUE), cbind(px1,px2,px3))
```

Método 2

```
prueba10.ajuste <- gofCopula(ellipCopula("t",
  c(0.5, 0.5, 0.5), dim = 3,
  dispstr = "un", df.fixed=TRUE),
  cbind(px1,px2,px3),
  N=500, method = "itau")
```

Se obtienen los siguientes resultados:

- Valor crítico (p-valor) = 0.524
- Estadístico de Cramer-von Mises = 0.031
- Parámetros estimados = (0.191, 0.541, 0.306)

Dado que el valor crítico de esta prueba es mayor al estadístico de Cramer-von Mises, no se rechaza la hipótesis nula; es decir, las probabilidades de los residuos (px_1 , px_2 , px_3) se ajustan a la cópula t.

Resumen de las cópulas ELÍPTICAS

En la tabla 5.6, se muestra para cada método de las cópulas Elípticas un resumen del estadístico de Cramer-von Mises, valores críticos y el resultado de la prueba de hipótesis.

Prueba Ajuste	Cramer-von Mises	P-Valor	Prueba de Hipótesis
Normal	0.0334	0.2485	se ajusta
t	0.0311	0.524	se ajusta

Tabla 5.6: Resumen cópulas ELÍPTICAS

5.5. CONSTRUCCIÓN DE LOS MODELOS CÓPULA

Considerando que únicamente no se ajustaron a la cópula de Clayton las probabilidades (p_{x1}, p_{x2}, p_{x3}) , se construirán modelos cópulas para Gumbel, Frank, Normal y t de Student; utilizando los parámetros estimados en las pruebas de bondad de ajuste efectuadas a las cópulas Arquimedianas y Elípticas.

■ Cópulas de Gumbel

```
gumbel.cop <- archmCopula("gumbel",
  param=prueba6.ajuste$parameter[[1]],
  dim=3, dispstr = "un")
```

■ Cópulas de Frank

```
frank.cop <- archmCopula("frank",
  param=prueba5.ajuste$parameter[[1]],
  dim=3, dispstr = "un")
```

■ Cópulas Normal

```
normal.cop <- ellipCopula("normal",
  c(prueba9.ajuste$parameter[[1]],
  prueba9.ajuste$parameter[[2]],
  prueba9.ajuste$parameter[[3]]),
  dim = 3, dispstr = "un")
```


- **Cóputas t de Student**

```
t.cop <- ellipCopula("t",
  c(prueba10.ajuste$parameter[[1]],
    prueba10.ajuste$parameter[[2]],
    prueba10.ajuste$parameter[[3]]),
  dim = 3, dispstr = "un")
```

A continuación, se presenta una representación gráfica en tres dimensiones de los cuatro modelos cópula que se construyeron: Gumbel, Frank, Normal y t de Student; para el efecto, se utilizó la función **rcopula** del software **R** para simular números aleatorios generados a partir de cada cópula Arquimediana y Elíptica.

- En la figura 5.1, se presenta la cópula de Gumbel en 3 dimensiones:

```
u1 <- rCopula(1000, gumbel.cop)
scatterplot3d(u1, mar=c(1, 2.5, 1, 2))
```




Figura 5.1: Gráfico en 3 dimensiones de la cópula de Gumbel

- En la figura 5.2, se presenta la cópula de Frank en 3 dimensiones:

```
u2 <- rCopula(1000, frank.cop)
scatterplot3d(u2, mar=c(1, 2.5, 1, 2))
```




Figura 5.2: Gráfico en 3 dimensiones de la cópula de Frank

- En la figura 5.3 , se presenta la cópula Normal en 3 dimensiones:

```
w1 <- rCopula(1000, normal.cop)
scatterplot3d(w1, mar=c(1, 2.5, 1, 2))
```




Figura 5.3: Gráfico en 3 dimensiones de la cópula Normal

- En la figura 5.4 , se presenta la cópula t en 3 dimensiones:

```
w2 <- rCopula(1000,t.cop)
scatterplot3d(w2,mar=c(1,2.5,1,2))
```




Figura 5.4: Gráfico en 3 dimensiones de la cópula t

Finalmente, se efectúa una calibración simultánea de la cópula y las marginales, de los modelos que se construyeron para las cópulas: Gumbel, Frank, Normal y t de Student; con el resultado de esta calibración se obtendrá el modelo final de cada cópula Arquimediana y Elíptica. El algoritmo que se implementó en el software **R** utiliza la función **mvdc**.

- Modelo final de la cópula de Gumbel:

```
modelo.gumbel <- mvdc(gumbel.cop,
  c("norm", "norm", "norm"),
  list(list(mean=y1[1], sd=y1[2]),
  list(mean=y2[1], sd=y2[2]),
  list(mean=y3[1], sd=y3[2])))
```

- Modelo final de la cópula de Frank:

```
modelo.frank <- mvdc(frank.cop,
  c("norm", "norm", "norm"),
```

```
list(list(mean=y1[1], sd=y1[2]),  
list(mean=y2[1], sd=y2[2]),  
list(mean=y3[1], sd=y3[2]))
```

- Modelo final de la cópula Normal:

```
modelo.normal <- mvdc(normal.cop,  
c("norm", "norm", "norm"),  
list(list(mean=y1[1], sd=y1[2]),  
list(mean=y2[1], sd=y2[2]),  
list(mean=y3[1], sd=y3[2])))
```

- Modelo final de la cópula t de Student:

```
modelo.t <- mvdc(t.cop,  
c("norm", "norm", "norm"),  
list(list(mean=y1[1], sd=y1[2]),  
list(mean=y2[1], sd=y2[2]),  
list(mean=y3[1], sd=y3[2])))
```

Capítulo 6

METODOLOGÍA PARA GESTIONAR EL RETIRO EN RIESGO

6.1. SIMULACIÓN DE NÚMEROS ALEATORIOS EN FUNCIÓN DE LAS CÓPULAS DE GUMBEL, FRANK, NORMAL Y t

Se generan 10,000 números aleatorios, utilizando la función *rMvdc*, para cada modelo cópula de Gumbel, Frank, Normal y t; respectivamente, para cada serie de depósitos corriente (x1), a plazo (x2) y ahorros (x3).

Cada valor estimado representa el logaritmo del porcentaje de retiro en el día (t) con respecto al saldo final del día (t-1).

El vector resultante de la simulación que contiene los 10,000 números aleatorios de cada cópula, considera la dependencia no lineal entre las fuentes de fondeo; consecuentemente, es posible implementar un algoritmo que nos permita calcular la distribución de retiros a través del modelo de autocorrelación (serie de tiempo), que se determinó para cada serie de depósitos.

Simulación de la cópula de Gumbel, Frank, Normal y t

```
> sim.gumbel <- rMvdc(10000,modelo.gumbel)
> sim.frank <- rMvdc(10000,modelo.frank)
> sim.normal <- rMvdc(10000,modelo.normal)
> sim.t <- rMvdc(10000,modelo.t)
```

En las tablas 6.1 , 6.2 , 6.3 , 6.4 ; se presentan los histogramas de los números aleatorios generados en cada cópula.

```
> hist(sim.gumbel,xlab = "Logaritmo porcentajes de retiro",
+      ylab = "Frecuencia", main = "HISTOGRAMA COPULA DE GUMBEL")
```

HISTOGRAMA COPULA DE GUMBEL




Figura 6.1: Cópula de Gumbel

```
> hist(sim.frank,xlab = "Logaritmo porcentajes de retiro",
+      ylab = "Frecuencia", main = "HISTOGRAMA COPULA DE FRANK")
```

HISTOGRAMA COPULA DE FRANK




Figura 6.2: Cópula de Frank

```
> hist(sim.normal,xlab = "Logaritmo porcentajes de retiro",
+      ylab = "Frecuencia", main = "HISTOGRAMA COPULA NORMAL")
```




Figura 6.3: Cópula Normal

```
> hist(sim.t,xlab = "Logaritmo porcentajes de retiro",
+      ylab = "Frecuencia", main = "HISTOGRAMA COPULA t")
```




Figura 6.4: Cópula t

6.2. ESTIMACIÓN DEL PARÁMETRO DE RETIRO INDIVIDUAL DE CADA FUENTE DE FONDEO

Para cada modelo cópula de Gumbel, Frank, Normal y t; se estima la distribución de retiros, a través de la ecuación de la serie temporal de cada fuente de fondeo:

- **Serie depósitos corriente:** $x_t = -1.4558 + 0.2140 * x_{t-1} + \mu_t$

- **Serie depósitos a plazo:** $x_t = -4.16468 - 0.03156 * x_{t-1} + \mu_t$

- **Serie depósitos ahorros:**

$$x_t = 0.6383 * x_{t-1} + 0.1399 * x_{t-2} - 0.1024 * x_{t-3} + 0.3242 * x_{t-4} + e_t$$

$$e_t = \sqrt{0.08105 + 0.24992 * e_{t-1}^2 + 0.4164 * \frac{e_{t-1}^2}{\mu_{t-1}^2}} * \mu_t$$

Cada valor estimado en la distribución de retiros, representa el porcentaje de retiro en (t) con respecto al saldo final del día (t-1).

Para el efecto, para cada fuente de fondeo analizada: corriente, a plazo y ahorros; se aplica el siguiente procedimiento:

- I. Se calcula la media y la desviación estándar de los números aleatorios simulados a través de cada cópula: Gumbel, Frank, Normal y t.
- II. Se generan 900,000 datos que sigan una distribución Normal con los siguientes parámetros:
 - media = media de los números aleatorios de la cópula de Gumbel
 - desviación estándar = z * desviación estándar de los números aleatorios de cada cópula: Gumbel, Frank, Normal y t; es decir, se utilizó como medida de dispersión al valor en riesgo al 95 % de dichos números aleatorios.
 - $\alpha = 95 \% \rightarrow z = 1.644854$

- III. Se estructura una matriz de dimensión (90 x 10,000); y, a través del modelo de series temporales determinado para cada fuente de fondeo, se estiman 90 observaciones con cada columna de dicha matriz.
- IV. Cada estimación representa el logaritmo del porcentaje de retiro en el día (t) versus el saldo final del día (t-1); por lo tanto, con el fin de determinar la distribución teórica de los retiros, se calcula el valor exponencial de cada observación estimada en el literal anterior.
- V. Se calcula la media de cada vector de retiros; y, sobre estos valores se calculan los parámetros: máximo, media, mediana y el percentil 95 %.

En la tabla 6.1, se presentan los resultados de la estimación del porcentaje de retiro individual que ocurrió en (t) versus el saldo de (t-1), para los parámetros: promedio, máximo, mediana y var 95 %, calculados en cada cópula; estos valores son comparados con la media de los datos reales¹.

parámetros	corriente	plazo	ahorros
media dato real	0.1636	0.0216	0.0707
media.Gumbel	0.1745	0.0321	0.0888
media.Frank	0.1729	0.0321	0.0895
media.Normal	0.1741	0.0316	0.0884
media.t	0.1735	0.0321	0.0886
max.Gumbel	0.2104	0.0734	0.1416
max.Frank	0.2094	0.0787	0.1328
max.Normal	0.2087	0.0701	0.155
max.t	0.2082	0.0688	0.1506
mediana.Gumbel	0.1742	0.0316	0.088
mediana.Frank	0.1727	0.0316	0.0887
mediana.Normal	0.174	0.0311	0.0876
mediana.t	0.1732	0.0315	0.0877
var95.Gumbel	0.1893	0.0411	0.1066
var95.Frank	0.1873	0.0413	0.1078
var95.Normal	0.1885	0.0405	0.1059
var95.t	0.1879	0.0413	0.1062

Tabla 6.1: Resultados del modelo: porcentajes de retiro

¹Los datos reales corresponden a la información de las fuentes analizadas: corriente, a plazo y ahorros, para las variables: saldo, retiro real y retiro estimado; para una ventana temporal de validación de **30 días** posteriores a los **90 días** del período de construcción.

En el **Anexo D** se detalla el código en R que se utilizó, para estimar el parámetro de retiro de cada serie de depósito analizada simulados a través de cada cópula.

6.3. ESTIMACIÓN DEL RETIRO GLOBAL

El retiro global estimado, se calcula como la suma del retiro individual estimado de cada fuente de fondeo analizada; entendiéndose que es posible efectuar la suma directa de ellas, dado que se ha considerado la autocorrelación y la correlación no lineal, a través de los modelos de series de tiempo y de cópulas, respectivamente.

En la estimación del retiro agregado, se utiliza como estadístico de estimación, el máximo valor que se registra en la distribución de retiros de cada fuente de fondeo; consecuentemente; éste es un criterio conservador, que justamente permite definir la máxima exposición de retiro que podría ocurrir en un determinado período tiempo, en función del comportamiento histórico de sus datos.

```
> porc.retiro.corriente <- max(as.numeric(
+                               c(result.porcent.retiro[14,2],
+                               result.porcent.retiro[15,2],
+                               result.porcent.retiro[16,2],
+                               result.porcent.retiro[17,2])))
> porc.retiro.plazo <- max(as.numeric(
+                               c(result.porcent.retiro[14,3],
+                               result.porcent.retiro[15,3],
+                               result.porcent.retiro[16,3],
+                               result.porcent.retiro[17,3])))
> porc.retiro.ahorros <- max(as.numeric(
+                               c(result.porcent.retiro[14,4],
+                               result.porcent.retiro[15,4],
+                               result.porcent.retiro[16,4],
+                               result.porcent.retiro[17,4])))
```

La fórmula que se aplica para estimar el retiro global es:

$$RG = \sum_3^{i=1} S(t-1)_f * \%R(t)_f$$

Donde:

$RG \rightarrow$ retiro global

$S_f \rightarrow$ saldo en el día (t-1) en la fuente de fondeo f = corriente, plazo, ahorros

$\%R_f \rightarrow$ porcentaje de retiro individual en el día (t) en la fuente de fondeo f = corriente, plazo, ahorros

Para $t = 1, 2, 3, 4, 5, \dots$, 125 días de cálculo

```
> estimado <- saldo.corriente*porc.retiro.corriente +
+           saldo.plazo*porc.retiro.plazo +
+           saldo.ahorros*porc.retiro.ahorros
```

6.4. CÁLCULO DEL RETIRO GLOBAL FINAL

Finalmente, a partir del retiro global de las tres fuentes de fondeo, se estima el retiro global final que ocurrirá en el día (i+1), conociendo el dato real del saldo en el día (i), para $i=1, 2, 3, \dots, 30$. En la mencionada metodología se involucran las siguientes definiciones:

- I. **Horizonte de provisión:** Contempla el nivel de liquidez que se requiere en función de los retiros, durante los próximos 30 días, posteriores a la fecha de estimación.
- II. **Límites de exposición:** La metodología de forma general, contempla límites de exposición que permiten cubrir los requerimientos de liquidez diarios, es decir, las obligaciones en el corto plazo; estableciéndose que no se mantengan excedentes de liquidez innecesarios, que encarezcan el costo del pasivo de las entidades financieras.

Para calcular el retiro global final, se utilizan dos bases de información:

- **Base de construcción.-** Está constituida por la información de las fuentes analizadas: corriente, a plazo y ahorros, para las variables: saldo, retiro real y retiro estimado; para el período de construcción de **90 días**.

```
> real3 <- real2[1:89]
> saldo3 <- saldo2[1:89]
> estimado3 <- estimado2[1:89]
```

- **Base de validación.-** Está constituida por la información de las fuentes analizadas: corriente, a plazo y ahorros, para las variables: saldo, retiro real y retiro estimado; para una ventana temporal de validación de **30 días** posteriores a los **90 días** del período de construcción.

```
> real4 <- real2[90:119]
> saldo4 <- saldo2[90:119]
> estimado4 <- estimado2[90:119]
```

6.4.1. FACTOR DE COBERTURA DE LIQUIDEZ

Con el fin de mantener un umbral de liquidez diario suficiente que permita cubrir las obligaciones en el corto plazo, sin recurrir a excedentes innecesarios que encarezcan el costo del pasivo, se define un factor que recopila los excesos de liquidez, el cual regula las fluctuaciones diarias de liquidez que se generan en las operaciones de captación y retiro de depósitos.

En el caso que se esté calculando este factor por primera vez, es necesario inicializar las variables del modelo, para lo cual se define el parámetro φ_0 , a través de la siguiente ecuación:

$$\varphi_0 = \text{saldo}_{t-1}(99\%) * \left[\frac{\text{retiro real}_t}{\text{saldo}_{t-1}} \right] (99\%)$$

Donde:

φ_0 → factor que regula los excesos de liquidez calculado para el día (t_0)

$\text{saldo}_{t-1}(99\%)$ → percentil 99 % del saldo total, que ocurrió en el día (t-1)

$\left[\frac{\text{retiro real}_t}{\text{saldo}_{t-1}} \right] (99\%)$ → percentil 99 % del cociente entre el retiro real total que ocurrió en el día (t) versus el saldo total que ocurrió en el día (t-1).

```

> factor.resto <- quantile(saldo3,0.99)*
+                       quantile(real3/saldo3,0.99)
> factor.resto <- factor.resto[[1]]
> estim <- matrix(nrow=29,ncol=1)
> for (i in 1:29)
+ estim[i,1] <- sum(estimado4[1:i])
> datoreal <- matrix(nrow=29,ncol=1)
> for (i in 1:29)
+ datoreal[i,1] <- sum(real4[1:i])
> fi0 <- matrix(nrow=29,ncol=1)
> for (i in 1:29) fi0[i,1] <- factor.resto

```

La estimación de φ_0 para los siguientes meses que se ejecute el modelo, será igual al valor de φ_j ; es decir, el valor final de φ en el mes anterior (t-1) con respecto al nuevo mes estimación (t).

Posteriormente, se determina el parámetro φ_j , para el horizonte temporal de estimación de 30 días; mediante la siguiente fórmula:

$$\varphi_j = \sum_{j=1}^{30} Estimado_j - \sum_{j=1}^{30} Real_j + \varphi_0$$

Donde:

φ_j → factor que regula los excesos de liquidez para el día j

$Estimado_j$ → estimación del retiro global para el día j

$Real_j$ → valor del retiro real para el día j

para j = 1, 2, 3,..., 30; días de estimación

```

> fi1 <- estim-datoreal+fi0
> fi2 <- as.numeric(fi1)
> fi3 <- c(factor.resto,fi2)
> fi4 <- matrix(fi3,nrow=30,ncol=1)
> superior <- function(fi4) ifelse(fi4>factor.resto,

```

```
+          factor.resto, fi4)
> fi5 <- apply(fi4, 1, superior)
```

6.4.2. METODOLOGÍA PARA ESTIMAR EL FLUJO DE COBERTURA DE LIQUIDEZ DIARIO

Una vez que hemos determinado el retiro global y el factor de cobertura de liquidez φ_j , se calcula el retiro global final, a través de la siguiente fórmula:

$$RGF_j = RG_j + (\varphi_{j-1})$$

Donde:

RGF_{j+1} → retiro global final que ocurrirá en el día (j)

RG_{j+1} → retiro global que ocurrirá en el día (j)

φ_{j-1} → excesos de liquidez que ocurrieron en el día (j-1)

para $j=1, 2, 3, \dots, 30$

```
> exceso <- fi4-fi5
> fitotal <- estimado4-real4+fi5
> estimado.final <- fitotal+real4
```

6.4.3. RESULTADOS DE LA METODOLOGÍA PARA ESTIMAR EL RETIRO GLOBAL FINAL

En función de la información real de los retiros y de los saldos de cada una de las fuentes de fondeo analizadas, para un horizonte temporal de predicción de 30 días, se efectuó una prueba de validación de las estimaciones denominada pruebas de backtesting, en la cual se contrastó el retiro real versus el retiro global estimado, en la figura 6.5 se presentan los resultados de la prueba antes mencionada:

```
> backtesting <- cbind(real4, fitotal)
> ts.plot(backtesting, col=c("blue", "red"),
+         lty=1:2, xlab = "PERIODO ANALIZADO (DIAS)",
```

```

+      ylab = "PORCENTAJE DE RETIRO",
+      main = "RETIRO REAL VERSUS ESTIMADO")

```




Figura 6.5: Gráfico de la prueba de validación diaria

Se puede evidenciar que durante todo el período de validación el retiro estimado es superior al retiro real; consecuentemente, se podrán cubrir las obligaciones de retiro diario de cada una de las fuentes de fondeo analizadas: corriente, a plazo y ahorros.

Adicionalmente, a través de dos tipos de reportes de monitoreo, se analizó el nivel de cobertura de la liquidez en función del retiro real versus el retiro estimado:

- I. **Reporte de índices de retiro con respecto al saldo total.**- Se calcularon tres índices de retiro diarios:
 - El primer índice dado por el retiro real que se registró durante el período de validación dividido para el saldo total de las tres fuentes de fondeo.

- El segundo índice dado por el retiro estimado global durante el período de validación; es decir, aquel que no considera el factor de ajuste a la cobertura de la liquidez, dividido para el saldo total de las tres fuentes de fondeo.
- El tercer índice dado por el retiro estimado global final durante el período de validación; es decir, aquel que si considera el factor de ajuste diario a la cobertura de la liquidez, dividido para el saldo total de las tres fuentes de fondeo.

En la tabla 6.2 , se presentan los indicadores antes descritos:

Indicador	Índices de retiro (%)
real / saldo	12.59
estimado global / saldo	13.88
estimado final / saldo	35.48

Tabla 6.2: Índices de retiro

Se puede observar que el índice de retiro estimado global es superior al índice de retiro real, por lo tanto, existe una cobertura suficiente de recursos para cubrir las obligaciones con los depositantes en los próximos 30 días.

Adicionalmente, al calcular los indicadores de liquidez estructural dados por la normativa de la Superintendencia de Bancos se obtuvieron los siguientes resultados:

Indicador	Volatilidad General	Valor en Riesgo
Primera línea	12.62	10.90
Segunda línea	15.78	13.63

Tabla 6.3: Indicadores de liquidez estructural, normativa vigente SB

Consecuentemente, si se compara el valor del indicador del retiro estimado global (13.88 %) versus los indicadores de liquidez estructural, se tiene que únicamente el indicador de segunda línea calculado con la metodología de la volatilidad general es superior (15.78 %)

Por otro lado, si se compara el indicador del retiro estimado global final (35.48 %) es superior al retiro real y a todos los indicadores de liquidez

estructural de primera línea y segunda línea calculados con la metodología de la volatilidad general y del valor en riesgo, vigentes en la normativa de la Superintendencia de Bancos.

II. **Reporte de cobertura con respecto al retiro real.**- Se calcularon dos índices de cobertura del retiro estimado versus el retiro real que se realizó durante el período de validación:

- El primer índice dado por el retiro estimado global, es decir, el retiro estimado que no considera el factor de ajuste a la cobertura de la liquidez versus el retiro real que se realizó durante el período de validación (30 días).
- El segundo índice dado por el retiro estimado global final, es decir, el retiro estimado que si considera el factor de ajuste a la cobertura de la liquidez versus el retiro real que se realizó durante el período de validación (30 días).

En la tabla 6.4, se presentan los indicadores antes descritos:

Indicador	Valor Cobertura (veces)
estimado global / retiro real	1.102
estimado final / retiro real	2.817

Tabla 6.4: Cobertura del retiro estimado versus el retiro real

Se puede observar que tanto el índice de cobertura dado por el retiro estimado global o por el retiro estimado global final dividido para el retiro real es superior a uno, consecuentemente, existen recursos líquidos suficientes para cubrir las obligaciones con los depositantes en los próximos 30 días.

En el caso del retiro estimado global final, que considera un factor de ajuste a los excesos de liquidez diarios; con el fin de no recurrir a excedentes innecesarios que encarezcan el costo del pasivo, se puede garantizar que están cubiertos inclusive eventos de retiro no esperados hasta en 2.8 veces.

Capítulo 7

CONCLUSIONES Y RECOMENDACIONES

7.1. CONCLUSIONES

- I. Se cumplió con el objetivo general de la investigación; es decir, se estableció un nuevo método de cálculo para estimar el requerimiento mínimo por riesgo de liquidez en función de la volatilidad de los depósitos.
- II. Se cumplieron con los objetivos específicos de esta investigación:
 - Se analizaron las metodologías que hasta el momento ha emitido la Superintendencia de Bancos; a través de regulaciones normativas, para cuantificar el riesgo de liquidez estructural, contractual, esperado y dinámico; así como la propuesta de modelos internos estadístico - matemáticos que se han definido en los acuerdos de Basilea, y otras mejores prácticas de gestión de riesgo de liquidez desarrolladas en el contexto internacional.
 - Se formuló un nuevo parámetro de medida que cuantifique la volatilidad del retiro de depósitos.
 - Se construyó un nuevo método de cálculo para estimar el nivel mínimo de los activos líquidos que requiere una institución financiera, para cubrir las obligaciones en el corto plazo, considerando la volatilidad de los pasivos.
 - Se desarrolló un esquema de administración del riesgo de liquidez en función de las estimaciones del retiro diario de los depósitos.
- III. Las metodologías que están vigentes en la normativa, presentan debilidades en la formulación de modelos y técnicas estadístico - matemáticas

que sustenten las estimaciones de las variables estocásticas implícitas en el riesgo de liquidez; adicionalmente, no se vinculan a ningún tipo de esquema de gestión del riesgo de liquidez de manera integral, como un mecanismo de **alerta temprana**.

IV. En este trabajo de investigación, se desarrollaron dos tipos de metodologías:

- Metodología para estimar la porción volátil de los depósitos a la vista y a plazo; es decir, cuantificar el riesgo de liquidez por **retiro de depósitos**.
- Metodología de control y monitoreo, en la cual se define un indicador de cobertura de la liquidez, así como reportes que permiten monitorear la liquidez periódicamente como un mecanismo de alerta temprana.

V. En la figura 7.1 , se presenta un esquema del desempeño de estas metodologías, orientadas a la gestión integral del riesgo de liquidez:



Figura 7.1: Esquema de administración del riesgo de liquidez

VI. La estimación de φ_0 para los siguientes meses que se ejecute el modelo, será igual al valor de φ_j para $j=30$; es decir, el valor final de φ que se registró en el mes anterior (T-1), con respecto al nuevo mes estimación (T).

VII. La estructura de este trabajo de investigación, tuvo como marco conceptual la **gestión integral de riesgos**, lo cual implicó que se desarrollen las siguientes fases:

- **Identificación:** Redefinición del parámetro de medida; para lo cual, se analizó el comportamiento de la variable retiro y no únicamente la variable saldo; consecuentemente, se mejoró la identificación del riesgo asociado a la liquidez de una institución financiera.
- **Medición:** Cuantificación del retiro en riesgo, a través de modelos estadístico - matemáticos, que permitan modelar el comportamiento de las variables estocásticas que intervienen en el riesgo de liquidez por retiro de depósitos.
- **Control:** Definición de límites de riesgo, que permitan regular las fluctuaciones diarias de liquidez que se generan en las operaciones de captación y retiro de depósitos.
- **Monitoreo:** Generación de reportes como mecanismos de alerta temprana, que permitan gestionar periódicamente la liquidez.

VIII. Con respecto a la temporalidad de la información y a la periodicidad de las estimaciones, se deben considerar las siguientes definiciones y lineamientos:

- La datos históricos de construcción tienen una ventana temporal de observación de 90 días.
- La variable estocástica **retiro de depósitos**, se estimó con una periodicidad **diaria**; es decir, se pronosticó diariamente el porcentaje y monto del retiro agregado e individual de las fuentes de fondeo analizadas: corriente, a plazo y a la vista.
- El horizonte de tiempo del pronóstico, es de 30 días; es decir, se está pronosticando el retiro **diario** de los depósitos que ocurrirán en los próximos 30 días.

IX. Al efectuar las pruebas de validación (backtesting) a los resultados del modelo, se pudo evidenciar que durante todo el período de observación el retiro estimado fue superior al retiro real; consecuentemente, se cubrirán

las obligaciones de retiro diario de cada una de las fuentes de fondeo analizadas: corriente, a plazo y ahorros.

- X. Se pudo evidenciar que tanto el índice de cobertura dado por el retiro estimado global o por el retiro estimado global final dividido para el retiro real es superior a uno; consecuentemente, existen recursos líquidos suficientes para cubrir las obligaciones con los depositantes en los próximos 30 días.
- XI. En el caso del retiro estimado global final, que considera un factor de ajuste para los excesos de liquidez diarios; con el fin de no recurrir a excedentes innecesarios que encarezcan el costo del pasivo, se puede garantizar que están cubiertos inclusive eventos de retiro no esperados hasta en 2.8 veces.
- XII. En el caso que se requiera ajustar el modelo estadístico y/o financiero, se deberá seguir los pasos descritos en el siguiente algoritmo:
- Revisar la consistencia de los datos históricos que ingresan al modelo, si es el caso que existan datos atípicos, perdidos o erróneos; efectuar tareas de depuración de la información.
 - Calcular el parámetro de medida $\%R_f(t_{i+1}) = \frac{R_f(t_{i+1})}{S_f(t_i)}$; para $i = 1, 2, \dots, 29$ y $f =$ corriente, plazo, ahorros.
 - Efectuar la prueba de raíces unitarias para los modelos: con constante y tendencia, solo con constante y sin constante ni tendencia; identificando si es o no necesario diferenciar la serie analizada.
 - Evaluar si se cumplen las pruebas de hipótesis de ausencia de autocorrelación y autocorrelación parcial en la serie original, los residuos y los residuos al cuadrado; en los casos que corresponda ajustar el modelo de media y varianza condicional.
 - Evaluar si los residuos de las series analizadas, presentan dependencia lineal o no lineal, en conjunto y por pares; es decir, se probará el supuesto de independencia para la terna (x_1, x_2, x_3) ; y, posteriormente para las dupletas (x_1, x_2) , (x_1, x_3) y (x_2, x_3) ; para $x_1 =$ corriente, $x_2 =$ plazo, $x_3 =$ ahorros.

- En el caso que exista dependencia lineal o no lineal, se deberá ajustar el modelo de cópulas.
- A través de la técnica de simulación construir la curva de retiros de cada serie analizada.
- Estimar el porcentaje de retiro de cada serie analizada.
- Determinar el valor (USD) del retiro individual y consolidado; así como los respectivos saldos individual y consolidado de cada serie analizada.
- Evaluar si los niveles de cobertura de liquidez mínima que genera el factor φ_j , están dentro de los límites de riesgo tolerados por la institución financiera; en el caso que se requiera regular los excesos de liquidez, se deberá ajustar el factor φ_0 .

7.2. RECOMENDACIONES

- I. Con respecto a la periodicidad de la calibración del modelo, se deben considerar las siguientes recomendaciones:
 - La periodicidad para evaluar el **modelo financiero de liquidez**, se recomienda que sea semanal; es decir, se deberá monitorear el factor que regula los excesos de liquidez φ_j con el fin de detectar si la relación entre el flujo estimado de retiro de depósitos versus el flujo real, sigue manteniendo un nivel de cobertura previamente definido como límite de riesgo. En este trabajo, como ejemplo de aplicación, se definió como nivel mínimo de liquidez una cobertura de 2.817 veces la relación entre el retiro estimado versus el retiro real. En el caso que se presente una relación inferior a 2.817 veces, se deberá corregir el factor φ_j o en su defecto calibrar el modelo de forma integral; es decir, ajustar el modelo estadístico y posteriormente el modelo financiero.
 - La periodicidad para evaluar y si es el caso calibrar el **modelo estadístico**, se recomienda que sea al menos semestral; particularmente, se deberán validar las hipótesis de ausencia de autocorrelación y correlación (lineal y no lineal); adicionalmente, en el caso que se

reajusten los modelos de series de tiempo o de cópulas, se deberá ejecutar todos los procesos de simulación necesarios para la construcción de la curva del retiro esperado individual y consolidado de las fuentes de fondeo analizadas.

- II. Con el fin de tener un parámetro de medida más cercano al comportamiento real del riesgo de liquidez dado por el retiro de depósitos; es necesario redefinir el parámetro de medida, considerando el porcentaje de retiro con respecto al saldo final del día anterior.
- III. Particularmente, este trabajo de tesis se centró en el análisis de la volatilidad de la liquidez estructural; sin embargo, este parámetro está relacionado con los reportes de liquidez esperada y dinámica, y con los reportes de brechas de liquidez por bandas de tiempo; por lo tanto, es necesario, estimar la volatilidad con técnicas estaísticas que evalúen la autocorrelación, así como la correlación lineal y no lineal de las fuentes de fondeo analizadas.
- IV. Incluir en las políticas y límites de riesgo, un indicador de cobertura que regule los excesos de liquidez; el mismo que deber ser dinámico en función de las necesidades de liquidez de cada institución financiera.
- V. Es necesario que se propongan en futuros temas de tesis, la investiguen de metodologías para cuantificar la **liquidez en riesgo** y el **flujo de caja en riesgo**, como complemento y tomando como insumo la metodología desarrollada en el presente trabajo de investigación.
- VI. Adecuar y en los casos que correspondan reformular las metodologías de cuantificación regulatorias en función de los modelos avanzados del riesgo de liquidez; y, si es el caso redefinir los reportes actuales que fortalezcan los mecanismos de alerta temprana para el ente de control y para las instituciones financieras, en función de las siguientes definiciones:
 - Retiro en riesgo, asociado a la volatilidad de los depósitos; se requiere reformular su cálculo según lo planteado en este trabajo de investigación.

- Liquidez en riesgo, asociado a la concentración de los depósitos; se requiere plantear una fórmula de cálculo, dado que en la normativa actual no se ha establecido ninguna forma de estimación de este parámetro.
- Flujo de caja en riesgo, esta metodología incorpora el retiro en riesgo y la liquidez en riesgo, constituyéndose en un reporte de la liquidez dinámica; es decir, la suma de los comportamientos determinísticos o contractuales más las variables estocásticas estimadas a través de modelos estadísticos.

Bibliografía

- [1] S. de Bancos y Seguros, *Nota técnica sobre riesgos de mercado y liquidez*. Resoluciones Nos. JB-2002-429 y JB-2002-431.
- [2] Castillo Edgar, *Generalizaciones de la metodología VaR para el análisis de riesgos de fondeo de liquidez, y margen financiero*, vol. 2. Revista de Administración, Finanzas y Economía, 2008.
- [3] Aguirre Sánchez Andrea Carolina, *TESIS: Monitoreo de la liquidez del Sistema Financiero Ecuatoriano: Una visión con medidas coherentes de riesgo*. Escuela Politécnica Nacional, 2010.
- [4] Maldonado Guerrero Diego Rolando and Pazmiño Barreno Ruth Mariela, *TESIS:*. Escuela Politécnica Nacional, 2009.
- [5] Artzner P., Eber J, and Heath D, *Coherent Measures of Risk*, vol. 9. Mathematical Finance, 1999.
- [6] Plascencia Cuevas Tania Nadiezhda, *TESIS DOCTORAL: Valoración del riesgo utilizando cópulas como medida de la dependencia: aplicación al sector financiero mexicano*. Madrid, <http://eprints.ucm.es/11121/1/T32093.pdf>, 2010. descargado el 05 de febrero de 2011.
- [7] Torres Avendaño Gabriel Ignacio and Olarte Cadavid Ana Milena, *Valor en riesgo desde un enfoque de cópulas*. Medellín, www.eafit.edu.co/revistas/administer/.../Artículo%206-rev%2015.pdf, Noviembre 2009. descargado el 05 de febrero de 2011.
- [8] Lara Haro Alfonso, *Medición y control de riesgos financieros*. México, Editorial Limusa S.A., tercera ed., 2008.

- [9] Cayuela Luis and Justel Ana, *Series temporales en R*. Madrid, Universidad Rey Juan Carlos, Universidad Autónoma de Madrid, Mayo 2012.
- [10] Villavicencio John Luis, *Introducción a Series de Tiempo*. www.estadisticas.gobierno.pr/iepr/LinkClick.aspx?fileticket, 2012.
- [11] Fernández Adrián, *Análisis de Series de Tiempo*. es.slideshare.net/erickaguilarochoa/series-de-tiempo-arima-i, 2010.
- [12] Uriel Ezequiel, *Análisis de Series de Temporales - Modelos ARIMA*. Colección Abaco, paraninfo ed., 1985.
- [13] Capa Santos Holger, *Modelación de Series de Temporales*. Escuela Politécnica Nacional - Departamento de Matemática, primera ed., 2007.
- [14] Bianco María José, Casparri María Teresa, and García Javier Ignacio, *Nota introductoria al concepto de Cópula y la problemática de riesgos extremos*. Universidad de Buenos Aires - Facultad de Ciencias Económicas, Mayo 2010.
- [15] Cintas del Río Rosario, *Teoría de Cópulas y Control de Riesgo Financiero*. Universidad Complutense de Madrid - Facultad de Ciencias Matemáticas, 2007.
- [16] Becerra Óscar and Melo Luis, *Medidas de Riesgo Financiero Usando Cópulas: Teoría y Aplicaciones*. Banco de la República - Colombia, 2008.
- [17] Denuit M. and Dhaene J., *Actuarial Theory for Dependent Risks - Measures, Orders and Models*. Université Catholique de Louvain, Belgium, Katholieke Universiteit Leuven, Belgium, Universiteit van Amsterdam, The Netherlands, Katholieke Universiteit Leuven, Belgium, Universiteit van Amsterdam, The Netherlands Universiteit van Amsterdam, The Netherlands, john wiley & sons, ltd ed., 2005.

Anexos

Anexo A

MODELOS DE SERIES DE TIEMPO QUE NO FUERON SELECCIONADOS: DEPÓSITOS CORRIENTE

A.1. MODELO 1: Arima(1,0,0) con b0

```
> ar.corriente1 <- Arima(ts.corriente, order=c(1,0,0),
+                         seasonal=list(order=c(0,0,0)),
+                         include.mean=TRUE,
+                         include.constant=TRUE)
> resid.corriente1<-ar.corriente1$residuals
> residsqr.corriente1<-resid.corriente1*resid.corriente1
```

Series: ts.corriente

ARIMA(1,0,0) with non-zero mean

Coefficients:

	ar1	intercept
	0.1987	0.1638
s.e.	0.1032	0.0063

sigma^2 estimated as 0.002332: log likelihood=145.01

AIC=-284.03 AICc=-283.75 BIC=-276.53

```
> fit1<-fitted.values(ar.corriente1)
```

```
> grafpred.corriente1<-cbind(ts.corriente[-90],fit1[-1])
```

```
> ts.plot(grafpred.corriente1,col=c("blue","red"), lty=1:2,
+         xlab ="PERIODO ANALIZADO (DIAS)",
```


Retardo	p-valor	Retardo	p-valor
1	0.9611	11	0.9440
2	0.9933	12	0.9595
3	0.8901	13	0.9746
4	0.8757	14	0.9787
5	0.9358	15	0.9695
6	0.8933	16	0.9789
7	0.9249	17	0.9852
8	0.9231	18	0.9911
9	0.9537	19	0.9309
10	0.9739		

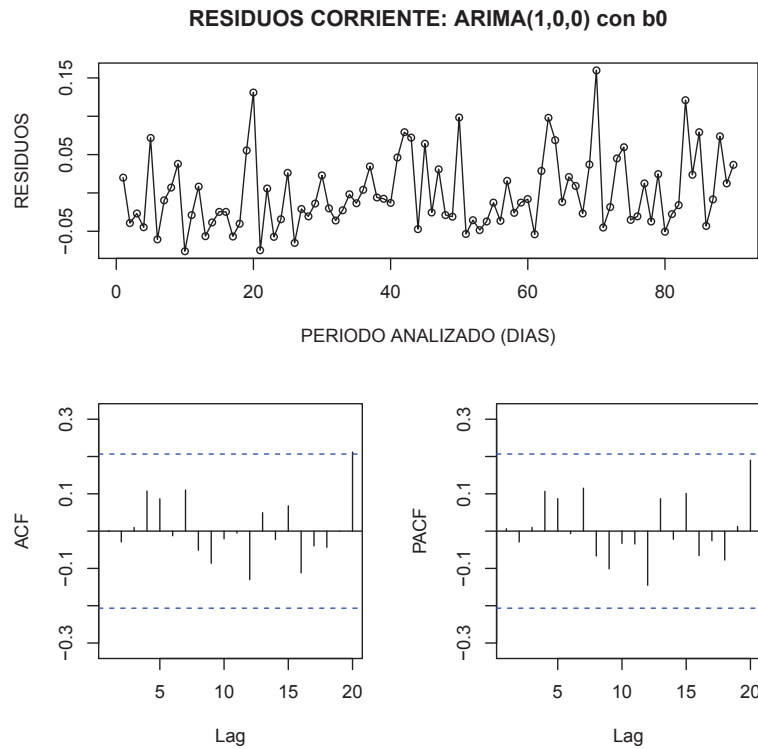
Tabla A.1: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)

```
> box2.corriente1<-numeric()
> for (i in 1:20)
+   box2.corriente1 <- c(box2.corriente1,
+                       round(Box.test(residsqr.corriente1,
+                                       lag=i)$p.value,4))
> mtestbox2.corriente1 <- matrix(box2.corriente1[-1],
+                                 nrow=19,ncol=1,
+                                 dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.7796	11	0.9556
2	0.9172	12	0.8448
3	0.8070	13	0.8615
4	0.8661	14	0.9020
5	0.9286	15	0.9060
6	0.9236	16	0.8968
7	0.9417	17	0.9257
8	0.9568	18	0.9450
9	0.9765	19	0.8528
10	0.9764		

Tabla A.2: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)


```
> tsdisplay(resid.corriente1,
+ main="RESIDUOS CORRIENTE: ARIMA(1,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.00637	-0.02899	11	-0.02903	0.01000
2	0.00962	0.10742	12	0.10656	0.08701
3	0.08671	-0.01227	13	-0.00681	0.11498
4	0.11018	-0.05124	14	-0.06660	-0.10118
5	-0.08631	-0.02073	15	-0.03289	-0.03452
6	-0.00523	-0.13014	16	-0.14519	0.08692
7	0.04953	-0.02255	17	-0.02175	0.10096
8	0.06765	-0.11186	18	-0.06556	-0.02560
9	-0.03972	-0.04341	19	-0.07745	0.01242
10	-0.00074	0.00637			

Tabla A.3: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente

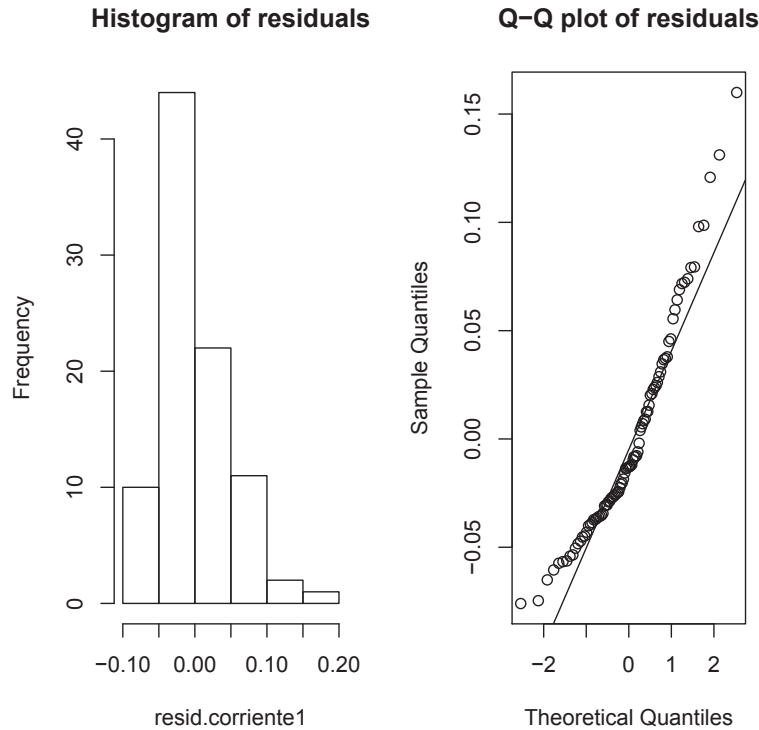
```
> tsdisplay(residsqr.corriente1,
+ main="RESIDUOS AL CUADRADO CORRIENTE:
+ ARIMA(1,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.03676	-0.06465	11	-0.06609	-0.00547
2	-0.01040	-0.11067	12	-0.11499	-0.04761
3	-0.05434	-0.01679	13	-0.02938	0.07909
4	0.08465	-0.06090	14	-0.08523	-0.05373
5	-0.05755	-0.01279	15	-0.02751	-0.07283
6	-0.07938	-0.12070	16	-0.13439	0.16957
7	0.17985	-0.07610	17	-0.14127	0.02174
8	-0.00422	-0.08637	18	-0.15259	-0.07791
9	-0.10447	-0.01698	19	-0.05200	-0.04272
10	-0.03666	0.03676			

Tabla A.4: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos corriente


```
> par(mfrow=c(1,2))
> hist(resid.corriente1,main="Histogram of residuals")
> qqnorm(resid.corriente1,main="Q-Q plot of residuals")
> qqline(resid.corriente1)
```



```
> shapiro.test(resid.corriente1)
```

Shapiro-Wilk normality test

W = 0.928, p-value = 9.228e-05

```
> x1 <- resid.corriente1
> y1 <- fitdistr(x1, "normal")$estimate
> ksy1 <-ks.test(x1, pnorm, mean=y1[1], sd=y1[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1401, p-value = 0.05271

alternative hypothesis: two-sided

```
> ady1 <- ad.test(x1, pnorm, mean=y1[1], sd=y1[2])
```

Anderson-Darling GoF Test

AD = 2.023, p-value = 0.08935

alternative hypothesis: NA

A.2. MODELO 2: Arima(1,0,0)(1,1,0) sin b0

```
> ar.corriente2 <- Arima(ts.corriente, order=c(1,0,0),  
+                       seasonal=list(order=c(1,1,0)),  
+                       include.mean=FALSE,  
+                       include.constant=FALSE)  
> resid.corriente2<-ar.corriente2$residuals  
> residsqr.corriente2<-resid.corriente2*resid.corriente2
```

Series: ts.corriente ARIMA(1,0,0)

Coefficients:

	ar1	sar1
	-0.2315	-0.2315
s.e.	0.1460	0.1460

sigma^2 estimated as 0.003234: log likelihood=128.77

AIC=-251.53 AICc=-251.25 BIC=-244.07

```
> fit2<-fitted.values(ar.corriente2)
```

```
> grafpred.corriente2<-cbind(ts.corriente[-90],fit2[-1])  
> ts.plot(grafpred.corriente2,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="DEPOSITOS CORRIENTE REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.0015	11	0.1187
2	0.0027	12	0.1499
3	0.0054	13	0.1887
4	0.0110	14	0.2097
5	0.0201	15	0.2128
6	0.0256	16	0.2433
7	0.0413	17	0.2620
8	0.0539	18	0.3092
9	0.0799	19	0.2266
10	0.1147		


Tabla A.5: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)

```
> box2.corriente2<-numeric()
> for (i in 1:20)
+   box2.corriente2 <- c(box2.corriente2,
+                         round(Box.test(residsqr.corriente2,
+                                       lag=i)$p.value,4))
> mtestbox2.corriente2 <- matrix(box2.corriente2[-1],
+                                 nrow=19,ncol=1,
+                                 dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.1095	11	0.7200
2	0.1641	12	0.6657
3	0.1382	13	0.6421
4	0.2207	14	0.7090
5	0.2767	15	0.7648
6	0.3751	16	0.6796
7	0.4738	17	0.7372
8	0.5302	18	0.7721
9	0.5658	19	0.7135
10	0.6472		

Tabla A.6: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)


```
> tdisplay(resid.corriente2,
+ main="RESIDUOS CORRIENTE: ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.07998	-0.37076	11	-0.37959	-0.21995
2	-0.11579	0.07799	12	-0.13812	-0.12107
3	0.04215	-0.04137	13	-0.12658	0.06049
4	0.10171	-0.03837	14	-0.07074	-0.05203
5	-0.08205	0.02833	15	0.00012	-0.05318
6	0.01372	-0.11195	16	-0.17435	-0.00684
7	0.05801	0.04790	17	-0.09566	0.08036
8	0.08687	-0.10934	18	-0.08158	-0.04904
9	-0.07165	-0.08966	19	-0.23028	-0.23189
10	-0.04209	-0.07998			

Tabla A.7: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente

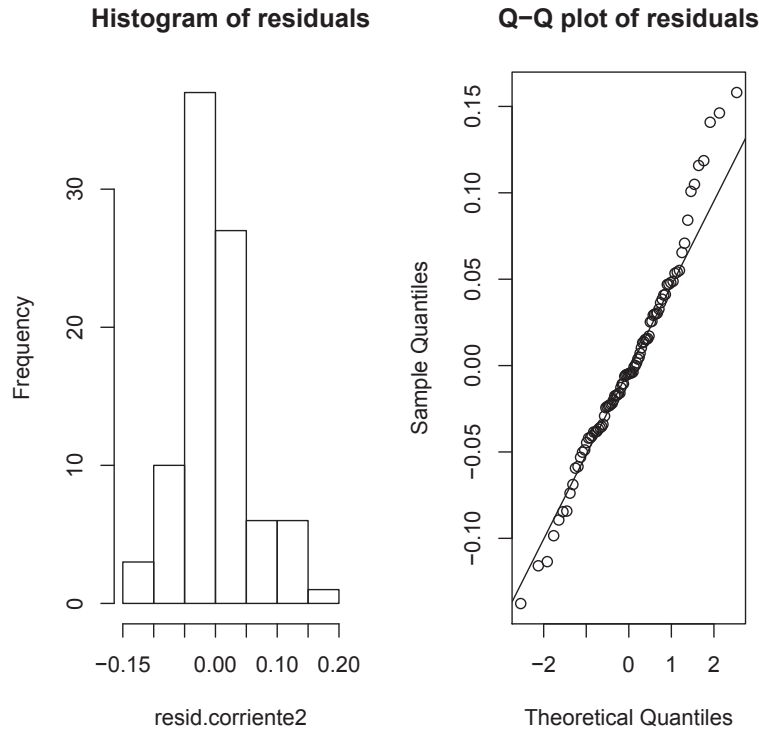
```
> tsdisplay(residsqr.corriente2,
+ main="RESIDUOS AL CUADRADO CORRIENTE:
+ ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.21853	0.03725	11	-0.01103	-0.09775
2	-0.08725	-0.14331	12	-0.10939	0.08531
3	0.02184	-0.07494	13	-0.10547	-0.00637
4	-0.01902	-0.02568	14	-0.02456	-0.06115
5	-0.07011	-0.08227	15	-0.08926	0.01509
6	-0.02938	-0.02845	16	-0.04747	0.12887
7	0.13099	-0.11597	17	-0.21455	0.04592
8	-0.02295	-0.03211	18	-0.04482	-0.14614
9	-0.15381	-0.02417	19	-0.03844	-0.01130
10	-0.05980	0.21853			

Tabla A.8: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos corriente

```
> par(mfrow=c(1,2))
> hist(resid.corriente2,main="Histogram of residuals")
> qqnorm(resid.corriente2,main="Q-Q plot of residuals")
> qqline(resid.corriente2)
```



```
> shapiro.test(resid.corriente2)
```

Shapiro-Wilk normality test

W = 0.9759, p-value = 0.0921

```
> x2 <- resid.corriente2
> y2 <- fitdistr(x2, "normal")$estimate
> ksy2 <-ks.test(x2, pnorm, mean=y2[1], sd=y2[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0722, p-value = 0.7081

alternative hypothesis: two-sided

```
> ady2 <- ad.test(x2, pnorm, mean=y2[1], sd=y2[2])
```

Anderson-Darling GoF Test

AD = 0.7262, p-value = 0.537

alternative hypothesis: NA

A.3. MODELO 3: Arima(2,0,0)(1,1,0) sin b0

```
> ar.corriente3 <- Arima(ts.corriente, order=c(2,0,0),
+                       seasonal=list(order=c(1,1,0)),
+                       include.mean=FALSE,
+                       include.constant=FALSE)
> resid.corriente3<-ar.corriente3$residuals
> residsqr.corriente3<-resid.corriente3*resid.corriente3
```

Series: ts.corriente ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1
	0.0119	-0.4879	-0.6252
s.e.	0.1164	0.1017	0.1122

sigma^2 estimated as 0.002685: log likelihood=136.82

AIC=-265.65 AICc=-265.17 BIC=-255.69

```
> fit3<-fitted.values(ar.corriente3)
```

```
> grafpred.corriente3<-cbind(ts.corriente[-90],fit3[-1])
> ts.plot(grafpred.corriente3,col=c("blue","red"), lty=1:2,
+        xlab ="PERIODO ANALIZADO (DIAS)",
+        ylab ="PORCENTAJE DE RETIRO",
+        main ="DEPOSITOS CORRIENTE REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.6068	11	0.7329
2	0.4593	12	0.7205
3	0.2635	13	0.7857
4	0.3571	14	0.8018
5	0.4779	15	0.7024
6	0.4583	16	0.6850
7	0.5446	17	0.6699
8	0.5585	18	0.7019
9	0.6495	19	0.4053
10	0.7221		


Tabla A.9: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)

```
> box2.corriente3<-numeric()
> for (i in 1:20)
+   box2.corriente3 <- c(box2.corriente3,
+                       round(Box.test(residsqr.corriente3,
+                                       lag=i)$p.value,4))
> mtestbox2.corriente3 <- matrix(box2.corriente3[-1],
+                                 nrow=19,ncol=1,
+                                 dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.2521	11	0.5554
2	0.4279	12	0.4417
3	0.5442	13	0.4610
4	0.6316	14	0.5361
5	0.6821	15	0.5945
6	0.7497	16	0.6474
7	0.8113	17	0.6847
8	0.7321	18	0.7383
9	0.7225	19	0.5637
10	0.5805		

Tabla A.10: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)


```
> tsdisplay(resid.corriente3,
+ main="RESIDUOS CORRIENTE: ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.05823	-0.08780	11	-0.09150	-0.14556
2	-0.13294	-0.17161	12	-0.20588	-0.00663
3	0.05450	-0.01573	13	-0.07659	0.06139
4	0.11514	-0.04759	14	-0.07371	-0.09692
5	-0.09622	-0.01779	15	-0.04478	-0.05059
6	-0.03538	-0.09095	16	-0.17888	0.03784
7	0.10678	0.00271	17	-0.05761	0.04825
8	0.08212	-0.16025	18	-0.19722	-0.13831
9	-0.11329	-0.11247	19	-0.24805	-0.21028
10	-0.06976	-0.05823			

Tabla A.11: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente

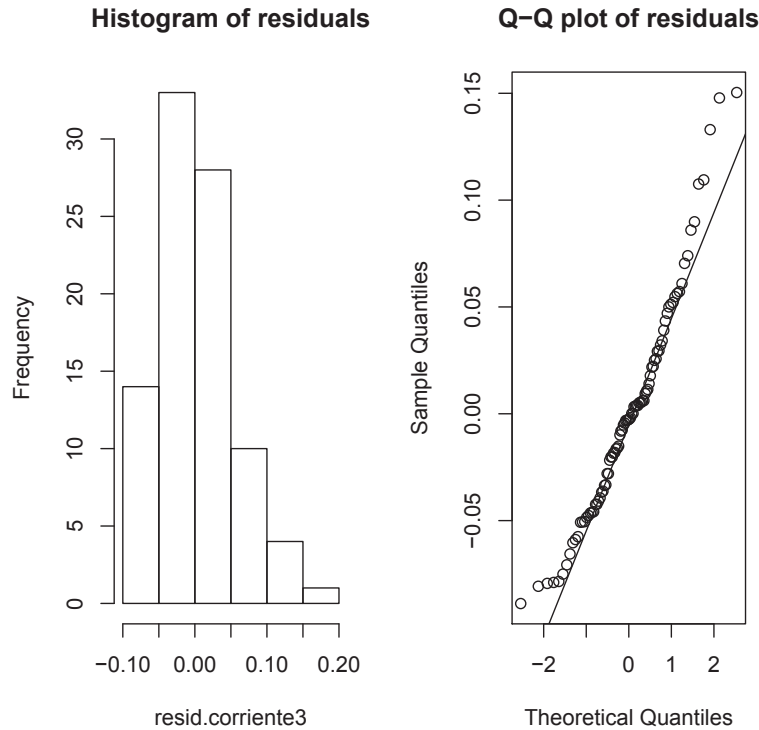
```
> tsdisplay(residsqr.corriente3,
+ main="RESIDUOS AL CUADRADO CORRIENTE:
+ ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="Residuos", xlab="Período analizado (días)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.05823	-0.08780	11	-0.09150	-0.14556
2	-0.13294	-0.17161	12	-0.20588	-0.00663
3	0.05450	-0.01573	13	-0.07659	0.06139
4	0.11514	-0.04759	14	-0.07371	-0.09692
5	-0.09622	-0.01779	15	-0.04478	-0.05059
6	-0.03538	-0.09095	16	-0.17888	0.03784
7	0.10678	0.00271	17	-0.05761	0.04825
8	0.08212	-0.16025	18	-0.19722	-0.13831
9	-0.11329	-0.11247	19	-0.24805	-0.21028
10	-0.06976	-0.05823			

Tabla A.12: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos corriente

```
> par(mfrow=c(1,2))
> hist(resid.corriente3,main="Histogram of residuals")
> qqnorm(resid.corriente3,main="Q-Q plot of residuals")
> qqline(resid.corriente3)
```



```
> shapiro.test(resid.corriente3)
```

Shapiro-Wilk normality test

W = 0.9594, p-value = 0.00672

```
> x3 <- resid.corriente3
> y3 <- fitdistr(x3, "normal")$estimate
> ksy3 <-ks.test(x3, pnorm, mean=y3[1], sd=y3[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1027, p-value = 0.2788

alternative hypothesis: two-sided

```
> ady3 <- ad.test(x3, pnorm, mean=y3[1], sd=y3[2])
```

Anderson-Darling GoF Test

AD = 0.8209, p-value = 0.4659

alternative hypothesis: NA

A.4. MODELO 4: Arima(2,0,0)(2,1,0) sin b0

```
> ar.corriente4 <- Arima(ts.corriente, order=c(2,0,0),  
+                       seasonal=list(order=c(2,1,0)),  
+                       include.mean=FALSE,  
+                       include.constant=FALSE)  
> resid.corriente4<-ar.corriente4$residuals  
> residsqr.corriente4<-resid.corriente4*resid.corriente4
```

Series: ts.corriente ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1	sar2
	-0.3016	-0.1911	-0.3016	-0.1911
s.e.	0.0279	0.0961	0.0279	0.0961

sigma^2 estimated as 0.002812: log likelihood=134.82

AIC=-259.64 AICc=-258.92 BIC=-247.2

```
> fit4<-fitted.values(ar.corriente4)
```

```
> grafpred.corriente4<-cbind(ts.corriente[-90],fit4[-1])  
> ts.plot(grafpred.corriente4,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="DEPOSITOS CORRIENTE REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.5940	11	0.5175
2	0.0439	12	0.5170
3	0.0836	13	0.5958
4	0.1312	14	0.5939
5	0.2043	15	0.5069
6	0.2325	16	0.4964
7	0.2964	17	0.4720
8	0.3661	18	0.5305
9	0.4364	19	0.3709
10	0.5261		


Tabla A.13: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(2,1,0)

```
> box2.corriente4<-numeric()
> for (i in 1:20)
+   box2.corriente4 <- c(box2.corriente4,
+                       round(Box.test(residsqr.corriente4,
+                                       lag=i)$p.value,4))
> mtestbox2.corriente4 <- matrix(box2.corriente4[-1],
+                                 nrow=19,ncol=1,
+                                 dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.5450	11	0.8164
2	0.6473	12	0.6857
3	0.6752	13	0.7114
4	0.6663	14	0.7708
5	0.6980	15	0.8250
6	0.7977	16	0.8508
7	0.7927	17	0.8728
8	0.7919	18	0.9002
9	0.8334	19	0.8596
10	0.8342		

Tabla A.14: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(2,1,0)

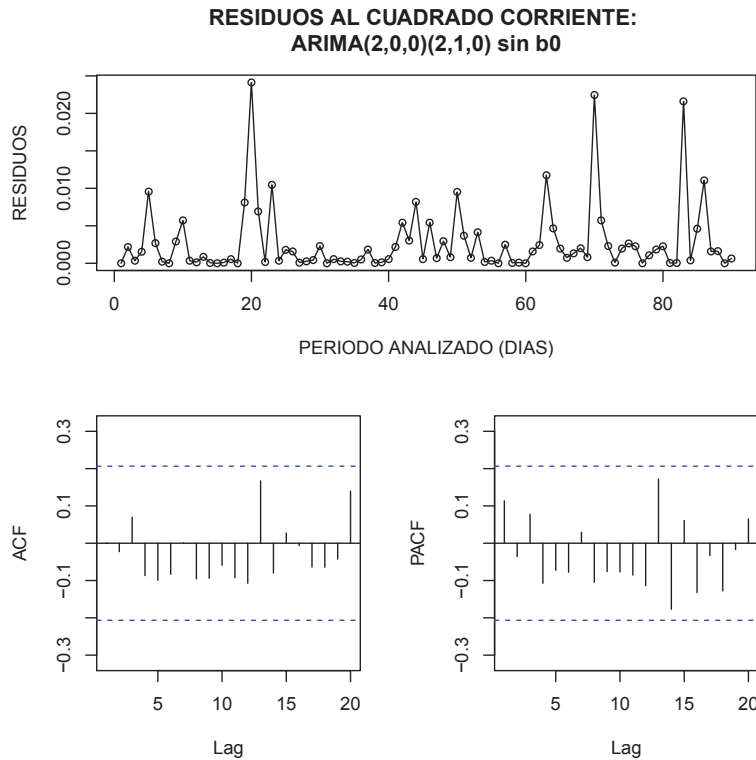

```
> tsdisplay(resid.corriente4,
+ main="RESIDUOS CORRIENTE: ARIMA(2,0,0)(2,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.05471	-0.09264	11	-0.09592	-0.29447
2	-0.28009	-0.03715	12	-0.09808	-0.02078
3	0.05416	-0.00339	13	-0.10960	0.05395
4	0.09423	-0.05593	14	-0.05115	-0.08024
5	-0.05135	-0.05141	15	-0.04065	-0.04739
6	0.00128	-0.10987	16	-0.19870	0.04778
7	0.10519	0.00238	17	-0.05795	0.03038
8	0.10427	-0.15402	18	-0.13300	-0.15594
9	-0.11281	-0.12310	19	-0.22367	-0.23111
10	-0.03762	-0.05471			

Tabla A.15: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos corriente

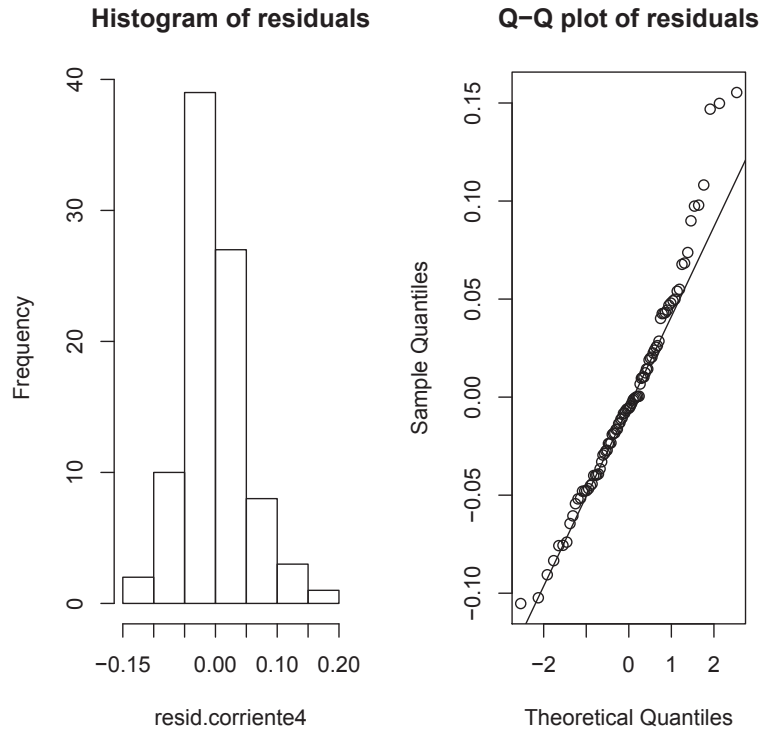
```
> tsdisplay(residsqr.corriente4,
+ main="RESIDUOS AL CUADRADO CORRIENTE:
+ ARIMA(2,0,0)(2,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.11392	-0.02263	11	-0.03608	0.07776
2	0.06987	-0.08674	12	-0.10724	-0.07264
3	-0.09933	-0.08325	13	-0.07785	0.02925
4	0.00080	-0.09564	14	-0.10462	-0.07627
5	-0.09433	-0.05907	15	-0.07710	-0.08545
6	-0.09257	-0.10736	16	-0.11363	0.17197
7	0.16706	-0.07981	17	-0.17711	0.06106
8	0.02702	-0.00627	18	-0.13244	-0.03321
9	-0.06387	-0.06431	19	-0.12775	-0.01722
10	-0.04248	0.11392			

Tabla A.16: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos corriente

```
> par(mfrow=c(1,2))
> hist(resid.corriente4,main="Histogram of residuals")
> qqnorm(resid.corriente4,main="Q-Q plot of residuals")
> qqline(resid.corriente4)
```



```
> shapiro.test(resid.corriente4)
```

Shapiro-Wilk normality test

W = 0.9649, p-value = 0.01569

```
> x4 <- resid.corriente4
> y4 <- fitdistr(x4, "normal")$estimate
> ksy4 <-ks.test(x4, pnorm, mean=y4[1], sd=y4[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1021, p-value = 0.2854

alternative hypothesis: two-sided

```
> ady4 <- ad.test(x4, pnorm, mean=y4[1], sd=y4[2])
```

Anderson-Darling GoF Test

AD = 0.7955, p-value = 0.4839

alternative hypothesis: NA

A.5. MODELO 5: Arima(1,0,0)(0,0,0) sin b0 (log corriente)

```
> ar.corriente5 <- Arima(log(ts.corriente), order=c(1,0,0),  
+                       seasonal=list(order=c(0,0,0)),  
+                       include.mean=FALSE,  
+                       include.constant=FALSE)  
> resid.corriente5<-ar.corriente5$residuals  
> residsqr.corriente5<-resid.corriente5*resid.corriente5
```

Series: log(ts.corriente) ARIMA(1,0,0) with zero mean

Coefficients:

```
      ar1  
      0.9809  
s.e.  0.0160
```

sigma^2 estimated as 0.1212: log likelihood=-34.39

AIC=72.79 AICc=72.93 BIC=77.79

```
> fit5<-fitted.values(ar.corriente5)
```

```
> grafpred.corriente5<-cbind(ts.corriente[-90],fit5[-1])  
> ts.plot(grafpred.corriente5,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS CORRIENTE REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.0007	11	0.0912
2	0.0023	12	0.1166
3	0.0055	13	0.1537
4	0.0105	14	0.1604
5	0.0128	15	0.1626
6	0.0144	16	0.2035
7	0.0244	17	0.2310
8	0.0366	18	0.2625
9	0.0555	19	0.2042
10	0.0793		


Tabla A.17: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)

```
> box2.corriente5<-numeric()
> for (i in 1:20)
+   box2.corriente5 <- c(box2.corriente5,
+                       round(Box.test(residsqr.corriente5,
+                                       lag=i)$p.value,4))
> mtestbox2.corriente5 <- matrix(box2.corriente5[-1],
+                                 nrow=19,ncol=1,
+                                 dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.9777	11	0.9798
2	0.8563	12	0.9890
3	0.9316	13	0.9806
4	0.9500	14	0.9806
5	0.9775	15	0.9886
6	0.9781	16	0.9864
7	0.9864	17	0.9901
8	0.9914	18	0.9923
9	0.9675	19	0.9901
10	0.9774		

Tabla A.18: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)


```
> tsdisplay(resid.corriente5,
+ main="RESIDUOS CORRIENTE: ARIMA(1,0,0)(0,0,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.38083	-0.12268	11	-0.31313	-0.26465
2	-0.02348	0.04391	12	-0.17460	-0.04891
3	0.06210	-0.11562	13	-0.15178	0.02897
4	0.12127	-0.03226	14	0.01625	-0.04260
5	-0.05601	0.03167	15	-0.00409	0.04549
6	0.03758	-0.09392	16	-0.10140	-0.00262
7	0.05992	-0.03112	17	-0.06673	0.07630
8	0.10583	-0.11150	18	-0.02497	0.03308
9	0.03352	-0.07392	19	-0.12662	-0.22719
10	-0.06876	-0.38083			

Tabla A.19: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo depósitos corriente

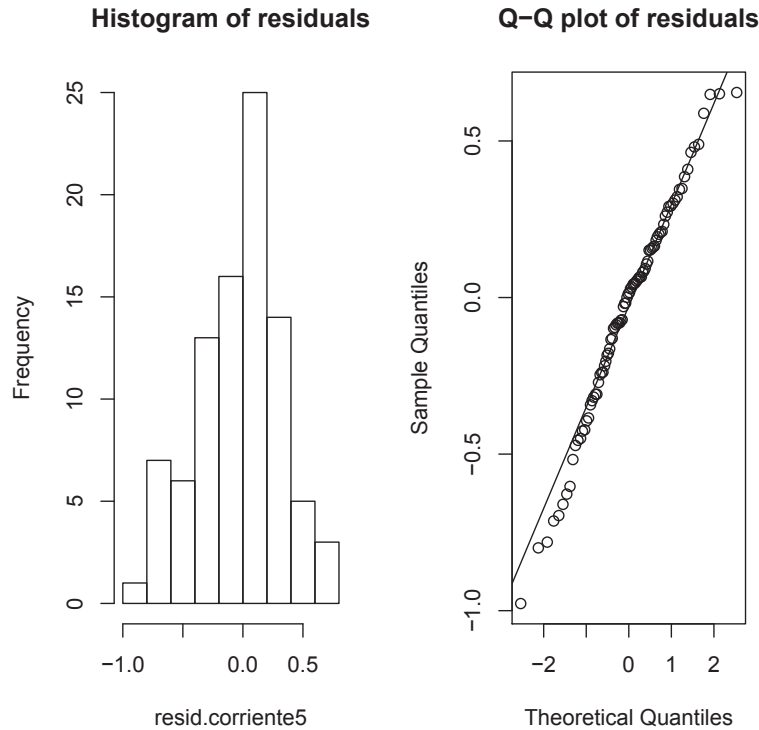
```
> tsdisplay(residsqr.corriente5,
+ main="RESIDUOS AL CUADRADO CORRIENTE:
+ ARIMA(1,0,0)(0,0,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.02063	-0.00864	11	-0.00907	-0.08952
2	-0.08984	0.02959	12	0.03346	0.05497
3	0.05722	-0.02165	13	-0.03214	-0.06245
4	-0.06892	-0.04622	14	-0.03491	-0.05451
5	-0.04686	-0.12835	15	-0.14307	0.05594
6	0.05088	-0.07225	16	-0.07855	-0.02508
7	-0.00538	-0.11257	17	-0.10206	0.08131
8	0.08287	0.00256	18	-0.02783	-0.13209
9	-0.09511	-0.05142	19	-0.03844	-0.08121
10	-0.05913	0.02063			

Tabla A.20: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo depósitos corriente


```
> par(mfrow=c(1,2))
> hist(resid.corriente5,main="Histogram of residuals")
> qqnorm(resid.corriente5,main="Q-Q plot of residuals")
> qqline(resid.corriente5)
```



```
> shapiro.test(resid.corriente5)
```

Shapiro-Wilk normality test

W = 0.9843, p-value = 0.3525

```
> x5 <- resid.corriente5
> y5 <- fitdistr(x5, "normal")$estimate
> ksy5 <-ks.test(x5, pnorm, mean=y5[1], sd=y5[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0751, p-value = 0.6619

alternative hypothesis: two-sided

```
> ady5 <- ad.test(x5, pnorm, mean=y5[1], sd=y5[2])
```

Anderson-Darling GoF Test

AD = 0.4215, p-value = 0.8268

alternative hypothesis: NA

A.6. MODELO 6: Arima(1,0,0)(1,1,0) sin b0 (log corriente)

```
> ar.corriente6 <- Arima(log(ts.corriente), order=c(1,0,0),  
+                       seasonal=list(order=c(1,1,0)),  
+                       include.mean=FALSE,  
+                       include.constant=FALSE)  
> resid.corriente6<-ar.corriente6$residuals  
> residsqr.corriente6<-resid.corriente6*resid.corriente6
```

Series: log(ts.corriente) ARIMA(1,0,0)

Coefficients:

	ar1	sar1
	-0.2395	-0.2395
s.e.	0.1449	0.1449

sigma^2 estimated as 0.1001: log likelihood=-23.96

AIC=53.92 AICc=54.21 BIC=61.39

```
> fit6<-fitted.values(ar.corriente6)
```

```
> grafpred.corriente6<-cbind(ts.corriente[-90],fit6[-1])  
> ts.plot(grafpred.corriente6,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS CORRIENTE REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.0014	11	0.1121
2	0.0027	12	0.1515
3	0.0050	13	0.1912
4	0.0102	14	0.2195
5	0.0177	15	0.2329
6	0.0226	16	0.2770
7	0.0379	17	0.2889
8	0.0459	18	0.3395
9	0.0686	19	0.2856
10	0.0985		


Tabla A.21: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)

```
> box2.corriente6<-numeric()
> for (i in 1:20)
+   box2.corriente6 <- c(box2.corriente6,
+                       round(Box.test(residsqr.corriente6,
+                                       lag=i)$p.value,4))
> mtestbox2.corriente6 <- matrix(box2.corriente6[-1],
+                                 nrow=19,ncol=1,
+                                 dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.4348	11	0.9172
2	0.4323	12	0.9136
3	0.3386	13	0.9090
4	0.4605	14	0.9386
5	0.5342	15	0.9566
6	0.6450	16	0.8831
7	0.7328	17	0.9104
8	0.8119	18	0.9245
9	0.8622	19	0.9126
10	0.8957		

Tabla A.22: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)


```
> tdisplay(resid.corriente6,
+ main="RESIDUOS CORRIENTE: ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.08232	-0.37420	11	-0.38357	-0.20929
2	-0.10309	0.08762	12	-0.12602	-0.10077
3	0.04549	-0.05833	13	-0.12432	0.07458
4	0.10216	-0.02073	14	-0.04979	-0.05867
5	-0.09755	0.03081	15	0.01438	-0.03958
6	0.02544	-0.09373	16	-0.14076	-0.01778
7	0.02147	0.04598	17	-0.07305	0.05104
8	0.07613	-0.09720	18	-0.07184	-0.03452
9	-0.04971	-0.09814	19	-0.22679	-0.19778
10	-0.03921	-0.08232			

Tabla A.23: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo depósitos corriente

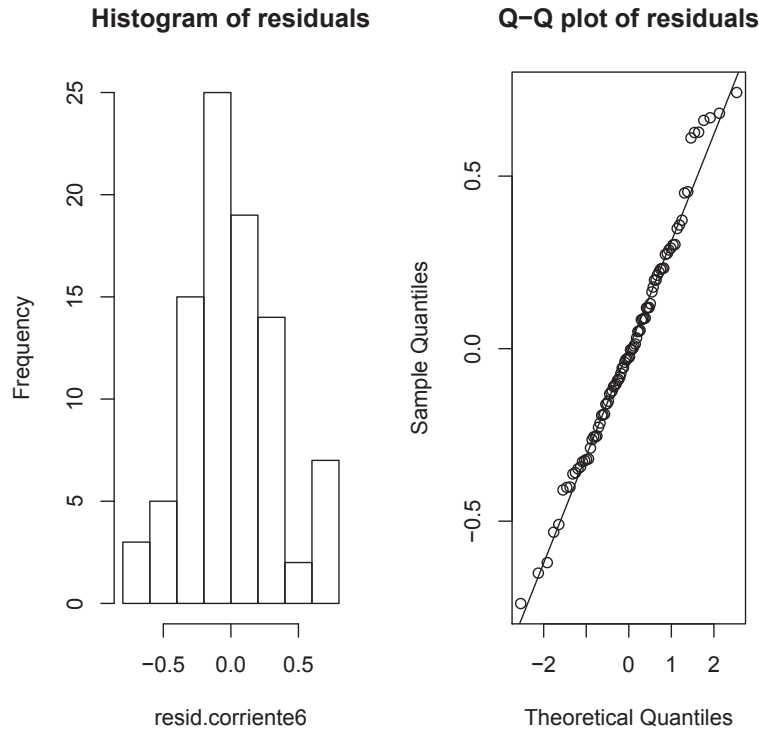
```
> tsdisplay(residsqr.corriente6,
+ main="RESIDUOS AL CUADRADO CORRIENTE:
+ ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.12522	0.05316	11	0.03808	-0.12290
2	-0.10963	-0.14089	12	-0.11837	0.08183
3	0.03547	-0.06901	13	-0.08390	-0.04372
4	-0.02293	-0.03436	14	-0.02201	-0.00484
5	-0.01546	-0.04196	15	-0.07106	0.06393
6	0.05163	-0.06050	16	-0.08465	0.09564
7	0.09381	-0.09617	17	-0.12915	0.02076
8	-0.00588	-0.03687	18	-0.05087	-0.15896
9	-0.17433	-0.03955	19	-0.05290	-0.01789
10	-0.06476	0.12522			

Tabla A.24: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo depósitos corriente

```
> par(mfrow=c(1,2))
> hist(resid.corriente6,main="Histogram of residuals")
> qqnorm(resid.corriente6,main="Q-Q plot of residuals")
> qqline(resid.corriente6)
```



```
> shapiro.test(resid.corriente6)
```

Shapiro-Wilk normality test

W = 0.9851, p-value = 0.3961

```
> x6 <- resid.corriente6
> y6 <- fitdistr(x6, "normal")$estimate
> ksy6 <-ks.test(x6, pnorm, mean=y6[1], sd=y6[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0523, p-value = 0.9554

alternative hypothesis: two-sided

```
> ady6 <- ad.test(x6, pnorm, mean=y6[1], sd=y6[2])
```

Anderson-Darling GoF Test

AD = 0.3467, p-value = 0.8992

alternative hypothesis: NA

A.7. MODELO 7: Arima(2,0,0)(1,1,0) sin b0 (log corriente)

```
> ar.corriente7 <- Arima(log(ts.corriente), order=c(2,0,0),  
+                       seasonal=list(order=c(1,1,0)),  
+                       include.mean=FALSE,  
+                       include.constant=FALSE)  
> resid.corriente7<-ar.corriente7$residuals  
> residsqr.corriente7<-resid.corriente7*resid.corriente7
```

Series: log(ts.corriente) ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1
	-0.0078	-0.4902	-0.6275
s.e.	0.1161	0.1016	0.1121

sigma^2 estimated as 0.08274: log likelihood=-15.74

AIC=39.48 AICc=39.96 BIC=49.43

```
> fit7<-fitted.values(ar.corriente7)
```

```
> grafpred.corriente7<-cbind(ts.corriente[-90],fit7[-1])  
> ts.plot(grafpred.corriente7,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS CORRIENTE REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.6485	11	0.7726
2	0.5123	12	0.8086
3	0.3030	13	0.8608
4	0.3743	14	0.8821
5	0.4921	15	0.8175
6	0.4905	16	0.8267
7	0.5868	17	0.7874
8	0.5833	18	0.8166
9	0.6754	19	0.6069
10	0.7468		


Tabla A.25: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)

```
> box2.corriente7<-numeric()
> for (i in 1:20)
+   box2.corriente7 <- c(box2.corriente7,
+                       round(Box.test(residsqr.corriente7,
+                                       lag=i)$p.value,4))
> mtestbox2.corriente7 <- matrix(box2.corriente7[-1],
+                                 nrow=19,ncol=1,
+                                 dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.3015	11	0.5202
2	0.4882	12	0.4911
3	0.6108	13	0.5383
4	0.6929	14	0.6136
5	0.7800	15	0.6282
6	0.8182	16	0.6784
7	0.7878	17	0.7221
8	0.6803	18	0.7614
9	0.7534	19	0.6762
10	0.6752		

Tabla A.26: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)


```
> tsdisplay(resid.corriente7,
+ main="RESIDUOS CORRIENTE: ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.05472	-0.08142	11	-0.08467	-0.13713
2	-0.12628	-0.16829	12	-0.19801	0.02261
3	0.07480	-0.02555	13	-0.07523	0.06219
4	0.10636	-0.03507	14	-0.05402	-0.09485
5	-0.10419	-0.00662	15	-0.03112	-0.03747
6	-0.03322	-0.07726	16	-0.15188	0.00781
7	0.06280	0.00358	17	-0.04000	0.02886
8	0.06641	-0.14750	18	-0.17848	-0.11179
9	-0.08683	-0.13006	19	-0.23920	-0.17752
10	-0.06200	-0.05472			

Tabla A.27: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo depósitos corriente

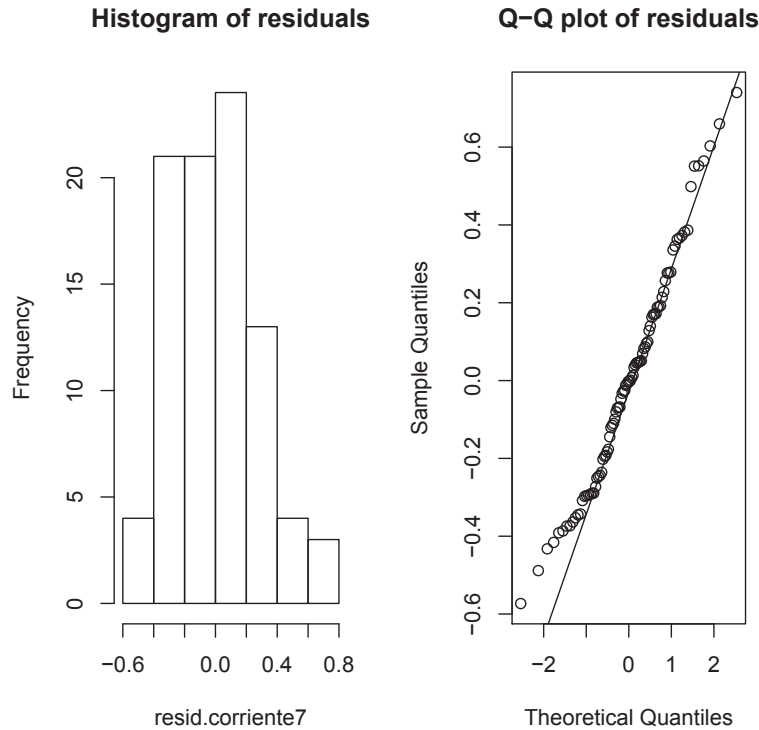
```
> tsdisplay(residsqr.corriente7,
+ main="RESIDUOS AL CUADRADO CORRIENTE:
+ ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.15811	-0.04056	11	-0.06724	0.03718
2	0.01861	-0.05396	12	-0.06811	-0.04065
3	-0.06281	-0.04469	13	-0.03632	0.08321
4	0.06932	-0.10821	14	-0.14510	-0.10030
5	-0.14422	-0.03583	15	-0.02331	-0.14051
6	-0.13826	-0.17260	16	-0.14708	0.15127
7	0.12241	-0.06678	17	-0.18150	0.06302
8	0.00427	-0.09133	18	-0.17870	-0.04046
9	-0.05121	-0.05441	19	-0.10741	-0.03820
10	-0.05471	0.15811			

Tabla A.28: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo depósitos corriente

```
> par(mfrow=c(1,2))
> hist(resid.corriente7,main="Histogram of residuals")
> qqnorm(resid.corriente7,main="Q-Q plot of residuals")
> qqline(resid.corriente7)
```



```
> shapiro.test(resid.corriente7)
```

Shapiro-Wilk normality test

W = 0.9787, p-value = 0.1475

```
> x7 <- resid.corriente7
> y7 <- fitdistr(x7, "normal")$estimate
> ksy7 <-ks.test(x7, pnorm, mean=y7[1], sd=y7[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.066, p-value = 0.804

alternative hypothesis: two-sided

```
> ady7 <- ad.test(x7, pnorm, mean=y7[1], sd=y7[2])
```

Anderson-Darling GoF Test

AD = 0.4998, p-value = 0.7465

alternative hypothesis: NA

Anexo B

MODELOS DE SERIES DE TIEMPO QUE NO FUERON SELECCIONADOS: DEPÓSITOS A PLAZO

B.1. MODELO 1: Arima(1,0,0)(0,0,0) con b0

```
> ar.plazo1 <- Arima(ts.plazo, order=c(1,0,0),
+                   seasonal=list(order=c(0,0,0)),
+                   include.mean=TRUE,
+                   include.constant=TRUE)
> resid.plazo1<-ar.plazo1$residuals
> residsqr.plazo1<-resid.plazo1*resid.plazo1
```

Series: ts.plazo ARIMA(1,0,0) with non-zero mean

Coefficients:

	ar1	intercept
	-0.0561	0.0216
s.e.	0.1050	0.0014

sigma^2 estimated as 0.0001966: log likelihood=256.33

AIC=-506.66 AICc=-506.38 BIC=-499.16

```
> fit1<-fitted.values(ar.plazo1)
```

```
> grafpred.plazo1<-cbind(ts.plazo[-90],fit1[-1])
> ts.plot(grafpred.plazo1,col=c("blue","red"), lty=1:2,
+        xlab ="PERIODO ANALIZADO (DIAS)",
+        ylab ="PORCENTAJE DE RETIRO",
+        main ="DEPOSITOS A PLAZO REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.9999	11	0.3116
2	0.9276	12	0.3753
3	0.9760	13	0.4505
4	0.9802	14	0.4495
5	0.6232	15	0.4849
6	0.6086	16	0.4421
7	0.4174	17	0.4974
8	0.3917	18	0.5477
9	0.2920	19	0.5963
10	0.3647		


Tabla B.1: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)

```
> box2.plazo1<-numeric()
> for (i in 1:20)
+   box2.plazo1 <- c(box2.plazo1,
+                   round(Box.test(residsqr.plazo1,
+                                 lag=i)$p.value,4))
> mtestbox2.plazo1 <- matrix(box2.plazo1[-1],
+                             nrow=19,ncol=1,
+                             dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.9350	11	0.7698
2	0.1617	12	0.8054
3	0.2373	13	0.7909
4	0.2234	14	0.7835
5	0.3218	15	0.7944
6	0.4299	16	0.8280
7	0.4922	17	0.8409
8	0.5829	18	0.8733
9	0.6692	19	0.9057
10	0.7260		

Tabla B.2: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)


```
> tsdisplay(resid.plazo1,
+ main="RESIDUOS A PLAZO: Arima(1,0,0)(0,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.00061	-0.00102	11	-0.00102	0.07148
2	0.07148	-0.01236	12	-0.01234	0.05565
3	0.05522	-0.20134	13	-0.20829	-0.10735
4	-0.10675	-0.17463	14	-0.19722	0.16337
5	0.12211	-0.16293	15	-0.17832	0.04379
6	-0.03122	0.14324	16	0.07487	-0.02548
7	-0.04051	-0.01074	17	-0.13732	0.16347
8	0.10730	0.07613	18	-0.00435	-0.14338
9	-0.13477	0.04645	19	0.00672	0.01683
10	-0.05242	-0.00061			

Tabla B.3: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo

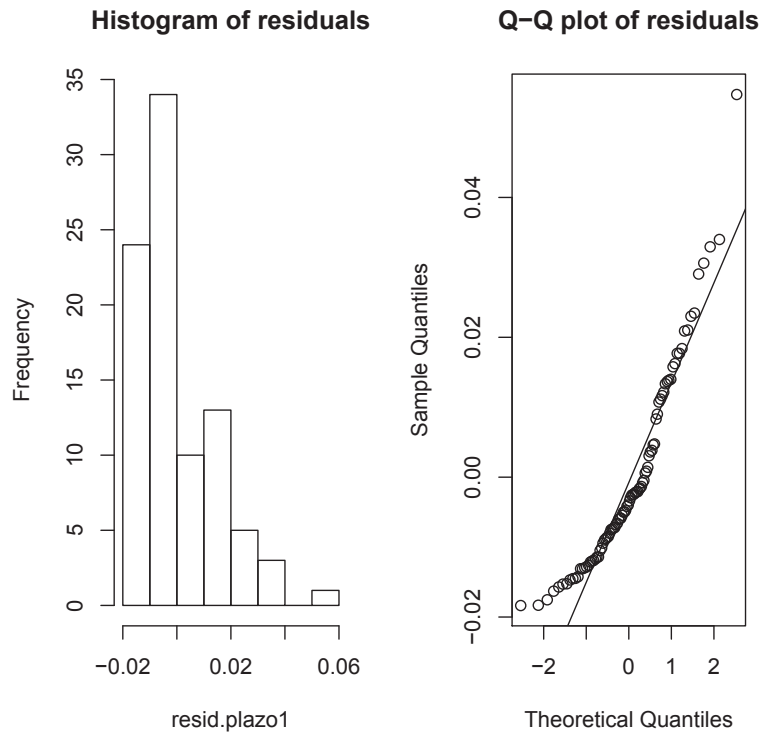
```
> tsdisplay(residsqr.plazo1,
+ main="RESIDUOS AL CUADRADO A PLAZO:
+ ARIMA(1,0,0)(0,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.03215	-0.02147	11	-0.02252	0.23480
2	0.23587	-0.06553	12	-0.05490	0.14058
3	0.12626	-0.01735	13	-0.07788	0.03809
4	-0.00228	-0.06901	14	-0.15367	0.01070
5	-0.03393	-0.02651	15	-0.08156	0.01902
6	-0.05492	0.06112	16	0.04396	-0.01048
7	-0.06370	-0.10746	17	-0.11200	0.09714
8	0.10305	-0.08740	18	-0.09616	-0.01259
9	-0.05626	0.08132	19	0.01687	0.03425
10	-0.04210	-0.03215			

Tabla B.4: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo

```
> par(mfrow=c(1,2))
> hist(resid.plazo1,main="Histogram of residuals")
> qqnorm(resid.plazo1,main="Q-Q plot of residuals")
> qqline(resid.plazo1)
```



```
> shapiro.test(resid.plazo1)
```

Shapiro-Wilk normality test

W = 0.8972, p-value = 3.038e-06

```
> x1 <- resid.plazo1
> y1 <- fitdistr(x1, "normal")$estimate
> ksy1 <-ks.test(x1, pnorm, mean=y1[1], sd=y1[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1594, p-value = 0.01826

alternative hypothesis: two-sided

```
> ady1 <- ad.test(x1, pnorm, mean=y1[1], sd=y1[2])
```

Anderson-Darling GoF Test

AD = 2.732, p-value = 0.03764

alternative hypothesis: NA

B.2. MODELO 2: Arima(1,0,0)(1,1,0) sin b0

```
> ar.plazo2 <- Arima(ts.plazo, order=c(1,0,0),  
+                   seasonal=list(order=c(1,1,0)),  
+                   include.mean=FALSE,  
+                   include.constant=FALSE)  
> resid.plazo2<-ar.plazo2$residuals  
> residsqr.plazo2<-resid.plazo2*resid.plazo2
```

Series: ts.plazo ARIMA(1,0,0)

Coefficients:

	ar1	sar1
	-0.3342	-0.3342
s.e.	0.1366	0.1366

sigma^2 estimated as 0.0002836: log likelihood=236.94

AIC=-467.89 AICc=-467.61 BIC=-460.42

```
> fit2<-fitted.values(ar.plazo2)
```

```
> grafpred.plazo2<-cbind(ts.plazo[-90],fit2[-1])  
> ts.plot(grafpred.plazo2,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="DEPOSITOS A PLAZO REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.0017	11	0.0093
2	0.0052	12	0.0126
3	0.0113	13	0.0157
4	0.0166	14	0.0128
5	0.0155	15	0.0159
6	0.0184	16	0.0121
7	0.0297	17	0.0169
8	0.0146	18	0.0236
9	0.0122	19	0.0332
10	0.0184		


Tabla B.5: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)

```
> box2.plazo2<-numeric()
> for (i in 1:20)
+   box2.plazo2 <- c(box2.plazo2,
+                   round(Box.test(residsqr.plazo2,
+                                 lag=i)$p.value,4))
> mtestbox2.plazo2 <- matrix(box2.plazo2[-1],
+                             nrow=19,ncol=1,
+                             dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.3174	11	0.8439
2	0.4863	12	0.8319
3	0.6463	13	0.8799
4	0.7116	14	0.8925
5	0.7836	15	0.8796
6	0.8175	16	0.9061
7	0.7671	17	0.9315
8	0.8246	18	0.9518
9	0.8717	19	0.9504
10	0.8956		

Tabla B.6: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)


```
> tsdisplay(resid.plazo2,
+ main="RESIDUOS A PLAZO: ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.11262	-0.35939	11	-0.37686	-0.11280
2	0.00261	0.05073	12	-0.12337	0.05564
3	0.09713	-0.14297	13	-0.16389	-0.12663
4	-0.11390	-0.04475	14	-0.24258	0.06048
5	0.19876	-0.15072	15	-0.31466	-0.03652
6	-0.05174	0.19875	16	-0.02152	-0.11411
7	-0.07672	-0.08937	17	-0.21466	0.11629
8	0.15267	0.08553	18	-0.02543	-0.11049
9	-0.16074	0.04686	19	0.02983	0.06802
10	0.03430	-0.11262			

Tabla B.7: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo

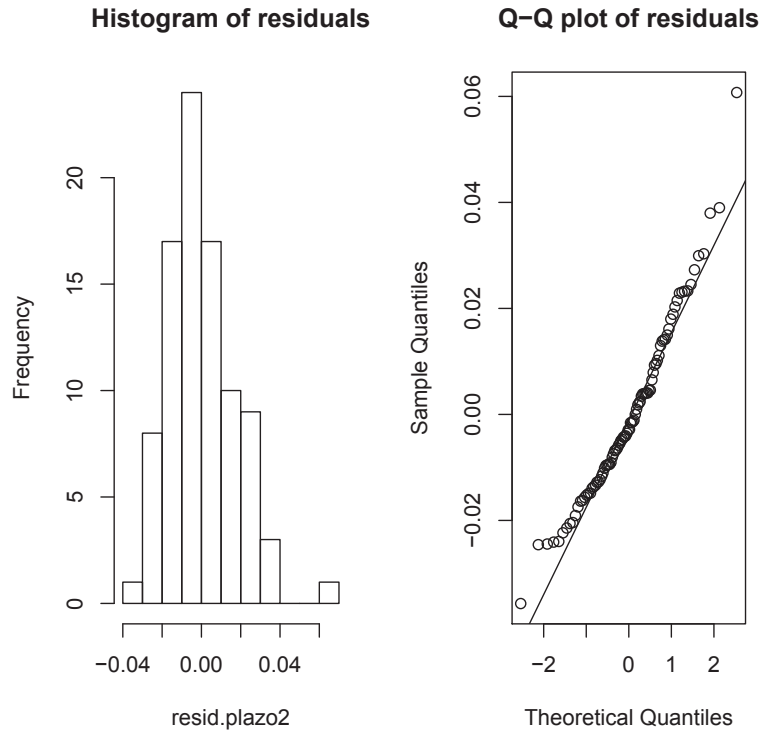

```
> tsdisplay(residsqr.plazo2,
+ main="RESIDUOS AL CUADRADO A PLAZO:
+ ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.09935	0.12504	11	0.11631	0.06405
2	0.04003	0.02380	12	0.01926	-0.08048
3	-0.06944	0.05512	13	0.03427	0.10025
4	0.07197	-0.11767	14	-0.10987	0.00143
5	0.04712	0.04342	15	0.06596	-0.04666
6	-0.06426	0.13131	16	0.12317	-0.10809
7	-0.10398	-0.00270	17	-0.04111	0.12735
8	0.07640	-0.10758	18	-0.13092	-0.06473
9	-0.04661	-0.02846	19	-0.01921	-0.03789
10	-0.01874	-0.09935			

Tabla B.8: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo

```
> par(mfrow=c(1,2))  
> hist(resid.plazo2,main="Histogram of residuals")  
> qqnorm(resid.plazo2,main="Q-Q plot of residuals")  
> qqline(resid.plazo2)
```



```
> shapiro.test(resid.plazo2)
```

Shapiro-Wilk normality test

W = 0.9642, p-value = 0.01407

```
> x2 <- resid.plazo2  
> y2 <- fitdistr(x2, "normal")$estimate  
> ksy2 <-ks.test(x2, pnorm, mean=y2[1], sd=y2[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0945, p-value = 0.3745

alternative hypothesis: two-sided

```
> ady2 <- ad.test(x2, pnorm, mean=y2[1], sd=y2[2])
```

Anderson-Darling GoF Test

AD = 0.8356, p-value = 0.4557

alternative hypothesis: NA

B.3. MODELO 3: Arima(2,0,0)(1,1,0) sin b0

```
> ar.plazo3 <- Arima(ts.plazo, order=c(2,0,0),  
+                   seasonal=list(order=c(1,1,0)),  
+                   include.mean=FALSE,  
+                   include.constant=FALSE)  
> resid.plazo3<-ar.plazo3$residuals  
> residsqr.plazo3<-resid.plazo3*resid.plazo3
```

Series: ts.plazo ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1
	-0.2742	-0.4044	-0.5396
s.e.	0.1573	0.1094	0.1594

sigma^2 estimated as 0.0002443: log likelihood=243.42

AIC=-478.84 AICc=-478.37 BIC=-468.89

```
> fit3<-fitted.values(ar.plazo3)
```

```
> grafpred.plazo3<-cbind(ts.plazo[-90],fit3[-1])  
> ts.plot(grafpred.plazo3,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="DEPOSITOS A PLAZO REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.6336	11	0.2494
2	0.6296	12	0.3085
3	0.5898	13	0.3782
4	0.6190	14	0.3915
5	0.3079	15	0.4057
6	0.3660	16	0.3911
7	0.2482	17	0.4288
8	0.1822	18	0.4937
9	0.2035	19	0.5582
10	0.2695		


Tabla B.9: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)

```
> box2.plazo3<-numeric()
> for (i in 1:20)
+   box2.plazo3 <- c(box2.plazo3,
+                   round(Box.test(residsqr.plazo3,
+                                 lag=i)$p.value,4))
> mtestbox2.plazo3 <- matrix(box2.plazo3[-1],
+                             nrow=19,ncol=1,
+                             dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.8323	11	0.9390
2	0.9448	12	0.9406
3	0.7656	13	0.9604
4	0.8528	14	0.9357
5	0.8196	15	0.9440
6	0.8269	16	0.9609
7	0.8632	17	0.9742
8	0.9071	18	0.9812
9	0.9254	19	0.9813
10	0.9046		

Tabla B.10: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)


```
> tsdisplay(resid.plazo3,
+ main="RESIDUOS A PLAZO: ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.05269	-0.08582	11	-0.08884	-0.10621
2	-0.09548	-0.10948	12	-0.13249	0.05547
3	0.08928	-0.20037	13	-0.23314	-0.12421
4	-0.07389	-0.17036	14	-0.26019	0.07393
5	0.16127	-0.09350	15	-0.26342	-0.06481
6	-0.00434	0.12827	16	-0.02761	-0.08187
7	-0.03735	0.01374	17	-0.21442	0.12553
8	0.09774	0.09627	18	-0.00531	-0.14574
9	-0.11885	0.07058	19	0.03897	0.08883
10	-0.01534	-0.05269			

Tabla B.11: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo

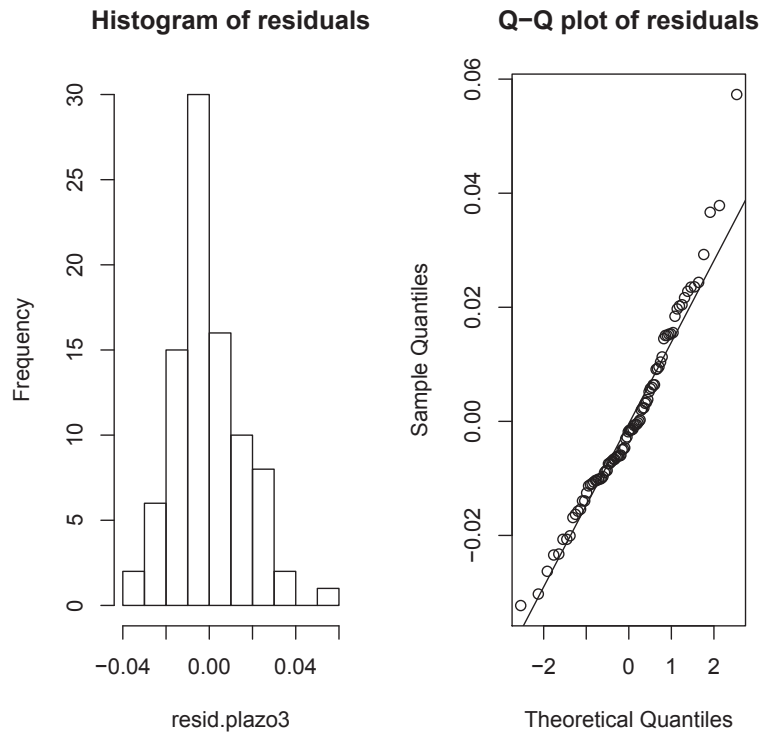
```
> tdisplay(residsqr.plazo3,
+ main="RESIDUOS AL CUADRADO A PLAZO:
+ ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.02377	-0.05927	11	-0.05987	0.00801
2	0.01089	0.12735	12	0.12480	-0.03207
3	-0.03890	0.10220	13	0.11687	0.08668
4	0.08591	-0.06276	14	-0.06370	-0.02497
5	-0.03839	-0.06450	15	-0.10831	-0.13962
6	-0.10851	0.00674	16	-0.00127	-0.12154
7	-0.08468	-0.02994	17	-0.00830	0.17874
8	0.12733	-0.07231	18	-0.05482	0.06318
9	-0.03166	-0.01712	19	-0.00902	-0.11268
10	-0.04684	-0.02377			

Tabla B.12: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo

```
> par(mfrow=c(1,2))
> hist(resid.plazo3,main="Histogram of residuals")
> qqnorm(resid.plazo3,main="Q-Q plot of residuals")
> qqline(resid.plazo3)
```



```
> shapiro.test(resid.plazo3)
```

Shapiro-Wilk normality test

W = 0.9622, p-value = 0.01032

```
> x3 <- resid.plazo3
> y3 <- fitdistr(x3, "normal")$estimate
> ksy3 <-ks.test(x3, pnorm, mean=y3[1], sd=y3[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.107, p-value = 0.2369

alternative hypothesis: two-sided


```
> ady3 <- ad.test(x3, pnorm, mean=y3[1], sd=y3[2])
```

Anderson-Darling GoF Test

AD = 1.019, p-value = 0.3472

alternative hypothesis: NA

B.4. MODELO 4: Arima(2,0,0)(2,1,0) sin b0

```
> ar.plazo4 <- Arima(ts.plazo, order=c(2,0,0),
+                   seasonal=list(order=c(2,1,0)),
+                   include.mean=FALSE,
+                   include.constant=FALSE)
> resid.plazo4<-ar.plazo4$residuals
> residsqr.plazo4<-resid.plazo4*resid.plazo4
```

Series: ts.plazo ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1	sar2
	-0.4113	-0.2067	-0.4113	-0.2067
s.e.	NaN	0.1346	NaN	0.1346

sigma^2 estimated as 0.0002428: log likelihood=243.68

AIC=-477.37 AICc=-476.64 BIC=-464.92

```
> fit4<-fitted.values(ar.plazo4)
```

```
> grafpred.plazo4<-cbind(ts.plazo[-90],fit4[-1])
> ts.plot(grafpred.plazo4,col=c("blue","red"), lty=1:2,
+        xlab ="PERIODO ANALIZADO (DIAS)",
+        ylab ="PORCENTAJE DE RETIRO",
+        main ="DEPOSITOS A PLAZO REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.6989	11	0.1763
2	0.4045	12	0.2281
3	0.5423	13	0.2877
4	0.5946	14	0.3175
5	0.1973	15	0.3090
6	0.2595	16	0.2914
7	0.1718	17	0.3303
8	0.1197	18	0.3901
9	0.1245	19	0.4522
10	0.1717		


Tabla B.13: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(2,1,0)

```
> box2.plazo4<-numeric()
> for (i in 1:20)
+   box2.plazo4 <- c(box2.plazo4,
+                   round(Box.test(residsqr.plazo4,
+                                 lag=i)$p.value,4))
> mtestbox2.plazo4 <- matrix(box2.plazo4[-1],
+                             nrow=19,ncol=1,
+                             dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.7420	11	0.9324
2	0.8924	12	0.9384
3	0.9299	13	0.9565
4	0.9578	14	0.9096
5	0.7396	15	0.9283
6	0.8108	16	0.9453
7	0.8558	17	0.9617
8	0.9104	18	0.9672
9	0.9333	19	0.9646
10	0.8971		

Tabla B.14: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(2,1,0)


```
> tdisplay(resid.plazo4,
+ main="RESIDUOS A PLAZO: ARIMA(2,0,0)(2,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.03315	-0.08284	11	-0.08404	-0.16349
2	-0.15639	-0.04417	12	-0.06713	0.04975
3	0.08153	-0.23354	13	-0.27304	-0.10034
4	-0.05827	-0.17182	14	-0.23867	0.04460
5	0.16705	-0.11252	15	-0.26039	-0.05266
6	0.01794	0.11025	16	-0.01399	-0.12167
7	-0.02692	0.01844	17	-0.18172	0.12708
8	0.08098	0.11719	18	-0.01758	-0.15624
9	-0.12528	0.06440	19	0.07633	0.06112
10	-0.01847	-0.03315			

Tabla B.15: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos a plazo

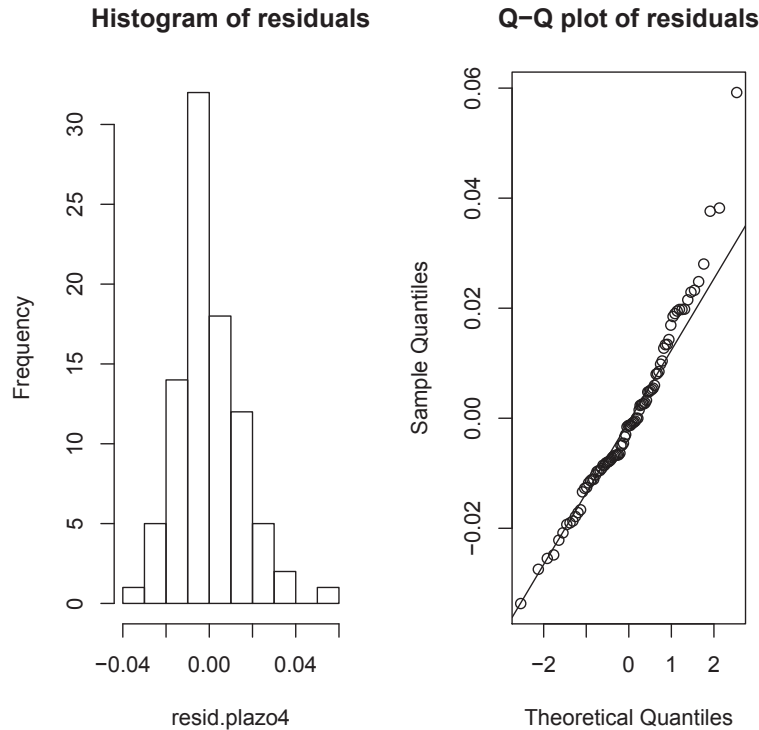
```
> tsdisplay(residsqr.plazo4,
+ main="RESIDUOS AL CUADRADO A PLAZO:
+ ARIMA(2,0,0)(2,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.02831	-0.07634	11	-0.07721	-0.01987
2	-0.01522	0.05218	12	0.04552	-0.04659
3	-0.04654	0.16584	13	0.17207	0.05155
4	0.04632	-0.05661	14	-0.03319	0.01190
5	-0.00448	-0.05517	15	-0.08427	-0.12433
6	-0.12187	0.01822	16	-0.02008	-0.12843
7	-0.07794	-0.04213	17	-0.03548	0.15779
8	0.14804	-0.05616	18	-0.04654	0.03956
9	-0.04894	-0.02949	19	-0.02265	-0.09404
10	-0.06977	-0.02831			

Tabla B.16: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos a plazo

```
> par(mfrow=c(1,2))
> hist(resid.plazo4,main="Histogram of residuals")
> qqnorm(resid.plazo4,main="Q-Q plot of residuals")
> qqline(resid.plazo4)
```



```
> shapiro.test(resid.plazo4)
```

Shapiro-Wilk normality test

W = 0.9598, p-value = 0.00706

```
> x4 <- resid.plazo4
> y4 <- fitdistr(x4, "normal")$estimate
> ksy4 <-ks.test(x4, pnorm, mean=y4[1], sd=y4[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0914, p-value = 0.4154

alternative hypothesis: two-sided

```
> ady4 <- ad.test(x4, pnorm, mean=y4[1], sd=y4[2])
```

Anderson-Darling GoF Test

AD = 0.9688, p-value = 0.3738

alternative hypothesis: NA

B.5. MODELO 5: Arima(1,0,0)(0,0,0) sin b0 (log a plazo)

```
> ar.plazo5 <- Arima(log(ts.plazo), order=c(1,0,0),  
+                   seasonal=list(order=c(0,0,0)),  
+                   include.mean=FALSE,  
+                   include.constant=FALSE)  
> resid.plazo5<-ar.plazo5$residuals  
> residsqr.plazo5<-resid.plazo5*resid.plazo5
```

Series: log(ts.plazo) ARIMA(1,0,0) with zero mean

Coefficients:

```
      ar1  
      0.9734  
s.e.  0.0206
```

sigma^2 estimated as 0.8937: log likelihood=-124.12

AIC=252.24 AICc=252.38 BIC=257.24

```
> fit5<-fitted.values(ar.plazo5)
```

```
> grafpred.plazo5<-cbind(log(ts.plazo)[-90],fit5[-1])  
> ts.plot(grafpred.plazo5,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS A PLAZO REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.0000	11	0.0001
2	0.0001	12	0.0001
3	0.0002	13	0.0002
4	0.0001	14	0.0003
5	0.0000	15	0.0003
6	0.0000	16	0.0001
7	0.0000	17	0.0001
8	0.0000	18	0.0002
9	0.0000	19	0.0004
10	0.0000		


Tabla B.17: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)

```
> box2.plazo5<-numeric()
> for (i in 1:20)
+   box2.plazo5 <- c(box2.plazo5,
+                   round(Box.test(residsqr.plazo5,
+                                 lag=i)$p.value,4))
> mtestbox2.plazo5 <- matrix(box2.plazo5[-1],
+                             nrow=19,ncol=1,
+                             dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.6928	11	0.3628
2	0.8574	12	0.4056
3	0.8860	13	0.4362
4	0.9177	14	0.4879
5	0.0934	15	0.5508
6	0.1395	16	0.6188
7	0.1842	17	0.6819
8	0.2256	18	0.7343
9	0.2936	19	0.7869
10	0.3488		

Tabla B.18: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)


```
> tsdisplay(resid.plazo5,
+ main="RESIDUOS A PLAZO: ARIMA(1,0,0)(0,0,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.49960	0.00146	11	-0.33068	-0.28448
2	-0.02589	-0.01137	12	-0.28064	0.02661
3	0.18131	-0.24199	13	-0.17232	-0.03040
4	0.15891	-0.15975	14	-0.21150	-0.02873
5	0.17887	-0.13989	15	-0.19324	-0.17999
6	0.01043	0.09147	16	-0.13459	-0.08873
7	-0.06686	0.03681	17	-0.15736	-0.03924
8	-0.02048	0.12262	18	0.12467	-0.10175
9	-0.22121	0.12446	19	-0.06255	-0.00575
10	0.00666	-0.49960			

Tabla B.19: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos a plazo

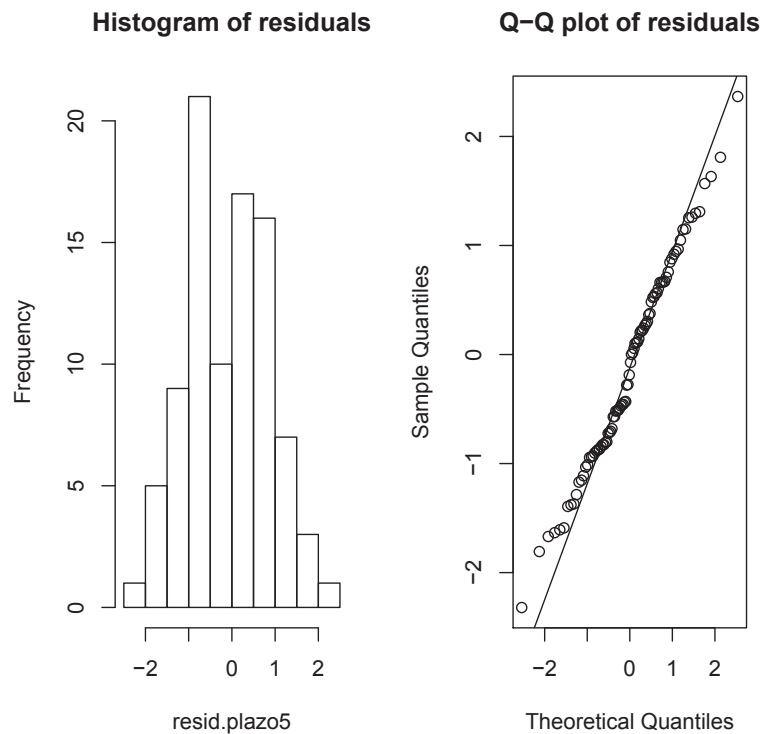
```
> tsdisplay(residsqr.plazo5,
+ main="RESIDUOS AL CUADRADO A PLAZO:
+ ARIMA(1,0,0)(0,0,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.04071	-0.08061	11	-0.08241	-0.01227
2	-0.01907	0.06539	12	0.06063	0.05114
3	0.05851	0.32287	13	0.33281	0.03292
4	0.03933	0.06145	14	0.12970	-0.07581
5	-0.07195	0.03100	15	0.00522	-0.13437
6	-0.06030	0.09925	16	-0.02421	0.02967
7	0.07240	-0.08325	17	-0.15527	0.01848
8	-0.05954	-0.03993	18	-0.09823	0.05278
9	-0.01880	-0.01851	19	-0.07059	0.05692
10	0.03459	0.04071			

Tabla B.20: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos a plazo

```
> par(mfrow=c(1,2))
> hist(resid.plazo5,main="Histogram of residuals")
> qqnorm(resid.plazo5,main="Q-Q plot of residuals")
> qqline(resid.plazo5)
```



```
> shapiro.test(resid.plazo5)
```

Shapiro-Wilk normality test

W = 0.9871, p-value = 0.5189

```
> x5 <- resid.plazo5
> y5 <- fitdistr(x5, "normal")$estimate
> ksy5 <-ks.test(x5, pnorm, mean=y5[1], sd=y5[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0991, p-value = 0.3188

alternative hypothesis: two-sided

```
> ady5 <- ad.test(x5, pnorm, mean=y5[1], sd=y5[2])
```

Anderson-Darling GoF Test

AD = 0.5328, p-value = 0.7131

alternative hypothesis: NA

B.6. MODELO 6: Arima(1,0,0)(1,1,0) sin b0 (log a plazo)

```
> ar.plazo6 <- Arima(log(ts.plazo), order=c(1,0,0),  
+                   seasonal=list(order=c(1,1,0)),  
+                   include.mean=FALSE,  
+                   include.constant=FALSE)  
> resid.plazo6<-ar.plazo6$residuals  
> resid sqr.plazo6<-resid.plazo6*resid.plazo6
```

Series: log(ts.plazo) ARIMA(1,0,0)

Coefficients:

	ar1	sar1
	-0.3031	-0.3031
s.e.	0.1491	0.1491

sigma^2 estimated as 0.6496: log likelihood=-107.28

AIC=220.57 AICc=220.85 BIC=228.03

```
> fit6<-fitted.values(ar.plazo6)
```

```
> grafpred.plazo6<-cbind(log(ts.plazo)[-90],fit6[-1])  
> ts.plot(grafpred.plazo6,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS A PLAZO REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.0019	11	0.0529
2	0.0037	12	0.0759
3	0.0069	13	0.1049
4	0.0074	14	0.1208
5	0.0055	15	0.1514
6	0.0107	16	0.0905
7	0.0180	17	0.1126
8	0.0254	18	0.1192
9	0.0316	19	0.1523
10	0.0482		


Tabla B.21: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)

```
> box2.plazo6<-numeric()
> for (i in 1:20)
+   box2.plazo6 <- c(box2.plazo6,
+                   round(Box.test(residsqr.plazo6,
+                                 lag=i)$p.value,4))
> mtestbox2.plazo6 <- matrix(box2.plazo6[-1],
+                             nrow=19,ncol=1,
+                             dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.8119	11	0.5751
2	0.7801	12	0.6553
3	0.8518	13	0.7258
4	0.7260	14	0.7601
5	0.4151	15	0.8074
6	0.5297	16	0.8151
7	0.5527	17	0.7876
8	0.4783	18	0.8351
9	0.5464	19	0.8469
10	0.6273		

Tabla B.22: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)


```
> tsdisplay(resid.plazo6,
+ main="RESIDUOS A PLAZO: ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.09501	-0.36036	11	-0.37276	-0.21883
2	-0.10431	0.08546	12	-0.12562	0.01124
3	0.13603	-0.16624	13	-0.20488	-0.01921
4	-0.00936	-0.04357	14	-0.19343	-0.02633
5	0.07516	-0.09323	15	-0.25189	-0.09913
6	-0.02085	0.10703	16	-0.10941	-0.10867
7	-0.01668	0.01499	17	-0.09584	0.10382
8	0.08519	0.04988	18	0.03886	-0.12525
9	-0.19555	0.05531	19	0.08423	0.04944
10	0.10220	-0.09501			

Tabla B.23: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos a plazo

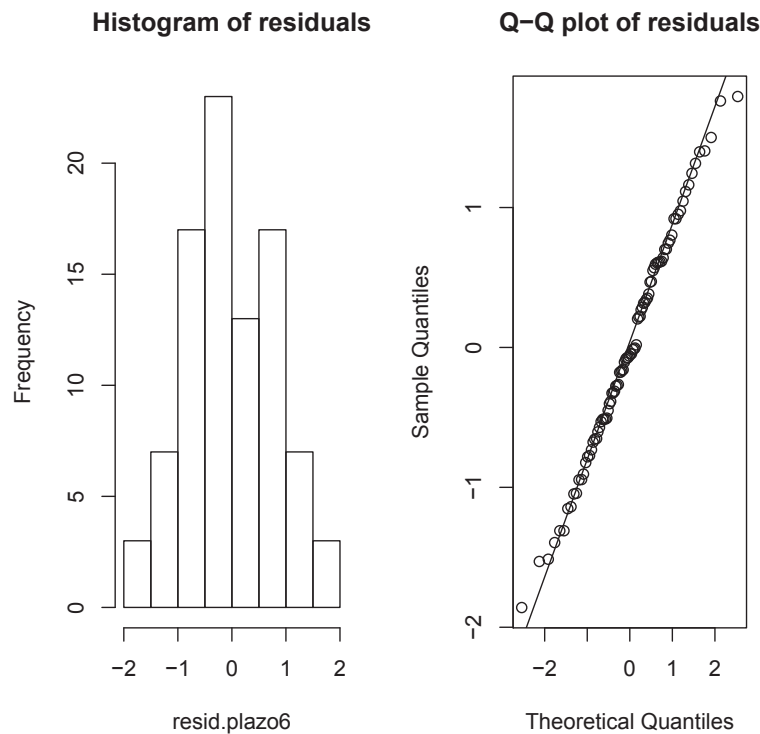

```
> tsdisplay(residsqr.plazo6,
+ main="RESIDUOS AL CUADRADO A PLAZO:
+ ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.03266	-0.05971	11	-0.06084	0.08266
2	0.08632	0.05463	12	0.05709	-0.11625
3	-0.12803	0.18977	13	0.18656	-0.02936
4	-0.01236	-0.09221	14	-0.06019	0.12973
5	0.13801	0.05623	15	0.01587	0.04011
6	-0.03190	0.13014	16	0.09863	-0.03202
7	0.00365	0.01482	17	0.08725	0.01654
8	0.06717	-0.03952	18	-0.07195	-0.04027
9	-0.08919	0.12096	19	0.05616	-0.00530
10	-0.00413	-0.03266			

Tabla B.24: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos a plazo

```
> par(mfrow=c(1,2))
> hist(resid.plazo6,main="Histogram of residuals")
> qqnorm(resid.plazo6,main="Q-Q plot of residuals")
> qqline(resid.plazo6)
```



```
> shapiro.test(resid.plazo6)
```

Shapiro-Wilk normality test

W = 0.9921, p-value = 0.8707

```
> x6 <- resid.plazo6
> y6 <- fitdistr(x6, "normal")$estimate
> ksy6 <-ks.test(x6, pnorm, mean=y6[1], sd=y6[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0621, p-value = 0.8563

alternative hypothesis: two-sided

```
> ady6 <- ad.test(x6, pnorm, mean=y6[1], sd=y6[2])
```

Anderson-Darling GoF Test

AD = 0.1917, p-value = 0.9925

alternative hypothesis: NA

B.7. MODELO 7: Arima(2,0,0)(1,1,0) sin b0 (log a plazo)

```
> ar.plazo7 <- Arima(log(ts.plazo), order=c(2,0,0),  
+                   seasonal=list(order=c(1,1,0)),  
+                   include.mean=FALSE,  
+                   include.constant=FALSE)  
> resid.plazo7<-ar.plazo7$residuals  
> residsqr.plazo7<-resid.plazo7*resid.plazo7
```

Series: log(ts.plazo) ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1
	-0.1051	-0.4587	-0.6479
s.e.	0.1217	0.1079	0.1131

sigma^2 estimated as 0.5546: log likelihood=-100.44

AIC=208.88 AICc=209.36 BIC=218.84

```
> fit7<-fitted.values(ar.plazo7)
```

```
> grafpred.plazo7<-cbind(log(ts.plazo)[-90],fit7[-1])  
> ts.plot(grafpred.plazo7,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS A PLAZO REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.5516	11	0.3558
2	0.4267	12	0.4253
3	0.3164	13	0.4515
4	0.2932	14	0.5117
5	0.1908	15	0.5489
6	0.2730	16	0.4251
7	0.1792	17	0.4434
8	0.2308	18	0.5018
9	0.2774	19	0.5428
10	0.3550		


Tabla B.25: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)

```
> box2.plazo7<-numeric()
> for (i in 1:20)
+   box2.plazo7 <- c(box2.plazo7,
+                   round(Box.test(residsqr.plazo7,
+                                 lag=i)$p.value,4))
> mtestbox2.plazo7 <- matrix(box2.plazo7[-1],
+                             nrow=19,ncol=1,
+                             dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.4988	11	0.7859
2	0.5603	12	0.8355
3	0.4260	13	0.8684
4	0.5316	14	0.8952
5	0.6232	15	0.9240
6	0.5826	16	0.9240
7	0.6410	17	0.8777
8	0.7342	18	0.8836
9	0.7771	19	0.8708
10	0.7144		

Tabla B.26: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)


```
> tsdisplay(resid.plazo7,
+ main="RESIDUOS A PLAZO: ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.08634	-0.07592	11	-0.08400	-0.14947
2	-0.13295	-0.14711	12	-0.18844	0.06534
3	0.12510	-0.16896	13	-0.21475	-0.06455
4	0.01464	-0.17293	14	-0.24901	-0.03838
5	0.05606	-0.06804	15	-0.25254	-0.11347
6	0.00095	0.10893	16	-0.10534	-0.02520
7	0.03514	0.08699	17	-0.09898	0.07044
8	0.04799	0.07359	18	0.03108	-0.15779
9	-0.17534	0.09120	19	0.08957	0.10812
10	0.03708	-0.08634			

Tabla B.27: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos a plazo

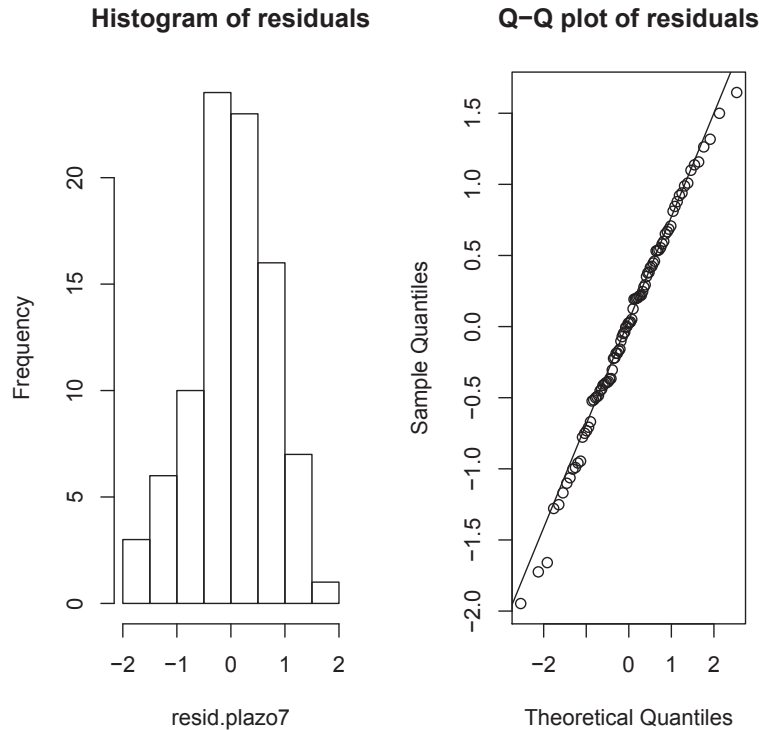
```
> tsdisplay(residsqr.plazo7,
+ main="RESIDUOS AL CUADRADO A PLAZO:
+ ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.03480	-0.11936	11	-0.12072	0.07850
2	0.08612	0.14129	12	0.13548	-0.02683
3	-0.05476	0.05491	13	0.07838	0.09494
4	0.11744	-0.06817	14	-0.06237	0.02241
5	0.00309	-0.06521	15	-0.11981	-0.16207
6	-0.13116	0.00514	16	-0.00773	-0.00231
7	0.03850	0.05375	17	0.11095	0.13502
8	0.05416	-0.03070	18	-0.00642	-0.05593
9	-0.09118	0.14516	19	0.12809	0.04211
10	0.08622	-0.03480			

Tabla B.28: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos a plazo

```
> par(mfrow=c(1,2))
> hist(resid.plazo7,main="Histogram of residuals")
> qqnorm(resid.plazo7,main="Q-Q plot of residuals")
> qqline(resid.plazo7)
```



```
> shapiro.test(resid.plazo7)
```

Shapiro-Wilk normality test

W = 0.9927, p-value = 0.9041

```
> x7 <- resid.plazo7
> y7 <- fitdistr(x7, "normal")$estimate
> ksy7 <-ks.test(x7, pnorm, mean=y7[1], sd=y7[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.056, p-value = 0.925

alternative hypothesis: two-sided


```
> ady7 <- ad.test(x7, pnorm, mean=y7[1], sd=y7[2])
```

Anderson-Darling GoF Test

AD = 0.1607, p-value = 0.9977

alternative hypothesis: NA

Anexo C

MODELOS DE SERIES DE TIEMPO QUE NO FUERON SELECCIONADOS: DEPÓSITOS DE AHORROS

C.1. MODELO 1: Arima(1,0,0)(0,0,0) con b0

```
> ar.ahorros1 <- Arima(ts.ahorros, order=c(1,0,0),
+                       seasonal=list(order=c(0,0,0)),
+                       include.mean=TRUE,
+                       include.constant=TRUE)
> resid.ahorros1<-ar.ahorros1$residuals
> residsqr.ahorros1<-resid.ahorros1*resid.ahorros1
```

Series: ts.ahorros ARIMA(1,0,0) with non-zero mean

Coefficients:

	ar1	intercept
	0.2963	0.0711
s.e.	0.1023	0.0073

sigma^2 estimated as 0.002369: log likelihood=144.29
AIC=-282.58 AICc=-282.31 BIC=-275.09

```
> fit1<-fitted.values(ar.ahorros1)
> grafpred.ahorros1<-cbind(ts.ahorros[-90], fit1[-1])
> ts.plot(grafpred.ahorros1, col=c("blue", "red"), lty=1:2,
+         xlab = "PERIODO ANALIZADO (DIAS)",
```


Retardo	p-valor	Retardo	p-valor
1	0.9428	11	0.9660
2	0.5896	12	0.9682
3	0.7505	13	0.9794
4	0.7937	14	0.9838
5	0.8775	15	0.9858
6	0.9220	16	0.9896
7	0.9546	17	0.9896
8	0.9340	18	0.9698
9	0.9321	19	0.9800
10	0.9580		


Tabla C.1: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)

```
> box2.ahorros1<-numeric()
> for (i in 1:20)
+   box2.ahorros1 <- c(box2.ahorros1,
+                       round(Box.test(residsqr.ahorros1,
+                                       lag=i)$p.value,4))
> mtestbox2.ahorros1 <- matrix(box2.ahorros1[-1],
+                               nrow=19,ncol=1,
+                               dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.3448	11	0.9480
2	0.5395	12	0.9579
3	0.6169	13	0.9630
4	0.6872	14	0.9707
5	0.7374	15	0.9772
6	0.7901	16	0.9821
7	0.8382	17	0.9869
8	0.8749	18	0.9794
9	0.9119	19	0.9857
10	0.9344		

Tabla C.2: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)


```
> tsdisplay(resid.ahorros1,
+ main="RESIDUOS AHORROS: ARIMA(1,0,0)(0,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.00697	0.03549	11	0.03545	-0.14112
2	-0.14142	-0.00475	12	-0.00736	-0.06338
3	-0.07189	-0.01922	13	-0.04016	-0.03950
4	-0.04054	-0.02980	14	-0.04920	-0.11618
5	-0.10462	-0.08708	15	-0.10922	0.00770
6	0.02374	-0.06489	16	-0.10742	-0.13339
7	-0.07815	-0.03438	17	-0.06553	-0.13099
8	-0.06158	-0.07136	18	-0.15611	-0.14628
9	-0.05278	-0.08261	19	-0.22607	0.00156
10	0.15453	-0.00697			

Tabla C.3: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros

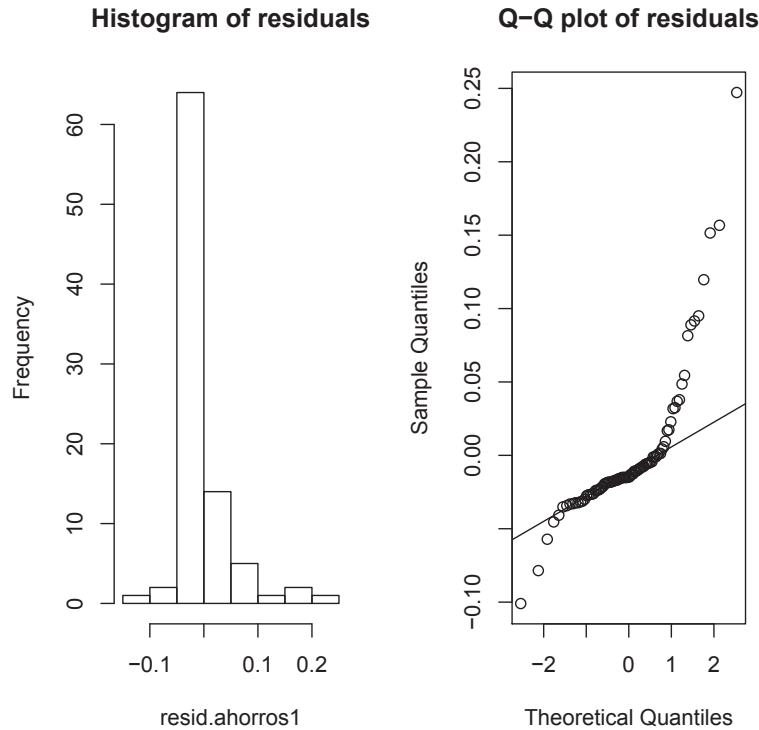
```
> tsdisplay(residsqr.ahorros1,
+ main="RESIDUOS AL CUADRADO AHORROS:
+ ARIMA(1,0,0)(0,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.15145	0.02695	11	0.00411	-0.02415
2	-0.01891	-0.07412	12	-0.06945	-0.04808
3	-0.06883	-0.07200	13	-0.05433	-0.04716
4	-0.06330	-0.05723	14	-0.04798	-0.05356
5	-0.05804	-0.04293	15	-0.04126	-0.05939
6	-0.05354	-0.06205	16	-0.06828	-0.07233
7	-0.06452	-0.07322	17	-0.08441	-0.07598
8	-0.06097	-0.05886	18	-0.08476	-0.09567
9	-0.06017	-0.05110	19	-0.09654	0.07721
10	0.11869	0.15145			

Tabla C.4: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos ahorros

```
> par(mfrow=c(1,2))
> hist(resid.ahorros1,main="Histogram of residuals")
> qqnorm(resid.ahorros1,main="Q-Q plot of residuals")
> qqline(resid.ahorros1)
```



```
> shapiro.test(resid.ahorros1)
```

Shapiro-Wilk normality test

W = 0.7289, p-value = 1.348e-11

```
> x1 <- resid.ahorros1
> y1 <- fitdistr(x1, "normal")$estimate
> ksy1 <-ks.test(x1, pnorm, mean=y1[1], sd=y1[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.263, p-value = 5.53e-06

alternative hypothesis: two-sided

```
> ady1 <- ad.test(x1, pnorm, mean=y1[1], sd=y1[2])
```

Anderson-Darling GoF Test

AD = 8.5671, p-value = 6.411e-05

alternative hypothesis: NA

C.2. MODELO 2: Arima(1,0,0)(1,1,0) sin b0

```
> ar.ahorros2 <- Arima(ts.ahorros, order=c(1,0,0),
+                      seasonal=list(order=c(1,1,0)),
+                      include.mean=FALSE,
+                      include.constant=FALSE)
> resid.ahorros2<-ar.ahorros2$residuals
> resid sqr.ahorros2<-resid.ahorros2*resid.ahorros2
```

Series: ts.ahorros ARIMA(1,0,0)

Coefficients:

	ar1	sar1
	-0.1853	-0.1853
s.e.	0.2248	0.2248

sigma^2 estimated as 0.003186: log likelihood=129.47

AIC=-252.94 AICc=-252.66 BIC=-245.47

```
> fit2<-fitted.values(ar.ahorros2)
```

```
> grafpred.ahorros2<-cbind(ts.ahorros[-90],fit2[-1])
> ts.plot(grafpred.ahorros2,col=c("blue","red"), lty=1:2,
+         xlab ="PERIODO ANALIZADO (DIAS)",
+         ylab ="PORCENTAJE DE RETIRO",
+         main ="DEPOSITOS AHORROS REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.1721	11	0.6900
2	0.0514	12	0.7484
3	0.1004	13	0.8072
4	0.1657	14	0.8576
5	0.2480	15	0.8930
6	0.3431	16	0.9017
7	0.4430	17	0.8430
8	0.5132	18	0.8813
9	0.5964	19	0.9126
10	0.6080		


Tabla C.5: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)

```
> box2.ahorros2<-numeric()
> for (i in 1:20)
+   box2.ahorros2 <- c(box2.ahorros2,
+                       round(Box.test(residsqr.ahorros2,
+                                       lag=i)$p.value,4))
> mtestbox2.ahorros2 <- matrix(box2.ahorros2[-1],
+                               nrow=19,ncol=1,
+                               dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.0000	11	0.0025
2	0.0000	12	0.0030
3	0.0001	13	0.0035
4	0.0002	14	0.0040
5	0.0003	15	0.0046
6	0.0004	16	0.0067
7	0.0006	17	0.0097
8	0.0008	18	0.0134
9	0.0013	19	0.0152
10	0.0019		

Tabla C.6: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)


```
> tsdisplay(resid.ahorros2,
+ main="RESIDUOS AHORROS: ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.02103	-0.19662	11	-0.19715	-0.23523
2	-0.21689	-0.01356	12	-0.08148	-0.13806
3	-0.02649	0.01958	13	-0.07553	-0.05743
4	0.01293	0.01525	14	-0.04545	-0.09914
5	-0.05835	-0.03692	15	-0.08349	0.04534
6	0.09533	-0.00186	16	-0.05832	-0.05667
7	-0.04329	0.02168	17	0.02352	-0.04376
8	-0.00747	-0.03313	18	-0.04985	-0.10957
9	-0.08029	-0.15038	19	-0.24868	-0.14486
10	0.01452	-0.02103			

Tabla C.7: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros

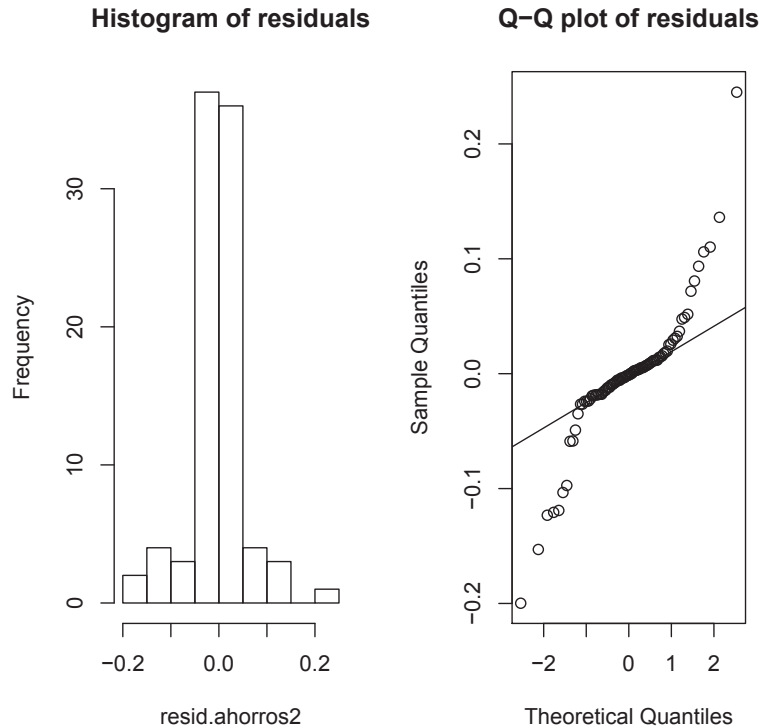
```
> tsdisplay(residsqr.ahorros2,
+ main="RESIDUOS AL CUADRADO AHORROS:
+ ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.49061	0.10657	11	-0.17664	0.04407
2	0.00728	-0.10091	12	-0.14337	0.02336
3	-0.10126	-0.10093	13	-0.08348	-0.02949
4	-0.10528	-0.09986	14	-0.06214	-0.05484
5	-0.10559	-0.07674	15	-0.01921	-0.07890
6	-0.08231	-0.09699	16	-0.05780	-0.08442
7	-0.10635	-0.10867	17	-0.06355	-0.09141
8	-0.11050	-0.10747	18	-0.08013	-0.01634
9	-0.04802	0.04086	19	0.01731	-0.05481
10	0.05048	0.49061			

Tabla C.8: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos ahorros

```
> par(mfrow=c(1,2))  
> hist(resid.ahorros2,main="Histogram of residuals")  
> qqnorm(resid.ahorros2,main="Q-Q plot of residuals")  
> qqline(resid.ahorros2)
```



```
> shapiro.test(resid.ahorros2)
```

Shapiro-Wilk normality test

```
data: resid.ahorros2  
W = 0.8432, p-value = 2.447e-08
```

```
> x2 <- resid.ahorros2  
> y2 <- fitdistr(x2, "normal")$estimate  
> ksy2 <-ks.test(x2, pnorm, mean=y2[1], sd=y2[2])
```

One-sample Kolmogorov-Smirnov test
D = 0.2061, p-value = 0.0007886
alternative hypothesis: two-sided

```
> ady2 <- ad.test(x2, pnorm, mean=y2[1], sd=y2[2])
```

Anderson-Darling GoF Test
AD = 5.3495, p-value = 0.00197
alternative hypothesis: NA

C.3. MODELO 3: Arima(2,0,0)(1,1,0) sin b0

```
> ar.ahorros3 <- Arima(ts.ahorros, order=c(2,0,0),  
+                      seasonal=list(order=c(1,1,0)),  
+                      include.mean=FALSE,  
+                      include.constant=FALSE)  
> resid.ahorros3<-ar.ahorros3$residuals  
> residshr.ahorros3<-resid.ahorros3*resid.ahorros3
```

Series: ts.ahorros ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1
	0.2307	-0.4051	-0.6618
s.e.	0.1232	0.1121	0.1067

sigma^2 estimated as 0.002915: log likelihood=133.31
AIC=-258.61 AICc=-258.14 BIC=-248.66

```
> fit3<-fitted.values(ar.ahorros3)
```

```
> grafpred.ahorros3<-cbind(ts.ahorros[-90], fit3[-1])  
> ts.plot(grafpred.ahorros3, col=c("blue", "red"), lty=1:2,  
+        xlab = "PERIODO ANALIZADO (DIAS)",  
+        ylab = "PORCENTAJE DE RETIRO",  
+        main = "DEPOSITOS AHORROS REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.8694	11	0.9548
2	0.8334	12	0.9699
3	0.5092	13	0.9810
4	0.5692	14	0.9819
5	0.6843	15	0.9859
6	0.7862	16	0.9739
7	0.8597	17	0.9503
8	0.9064	18	0.9612
9	0.9342	19	0.9729
10	0.9273		


Tabla C.9: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(1,1,0)

```
> box2.ahorros3<-numeric()
> for (i in 1:20)
+   box2.ahorros3 <- c(box2.ahorros3,
+                       round(Box.test(residsqr.ahorros3,
+                                       lag=i)$p.value,4))
> mtestbox2.ahorros3 <- matrix(box2.ahorros3[-1],
+                               nrow=19,ncol=1,
+                               dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.0009	11	0.0574
2	0.0027	12	0.0622
3	0.0067	13	0.0680
4	0.0104	14	0.0814
5	0.0154	15	0.0904
6	0.0205	16	0.1171
7	0.0258	17	0.1474
8	0.0300	18	0.1781
9	0.0395	19	0.1948
10	0.0501		

Tabla C.10: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(1,1,0)

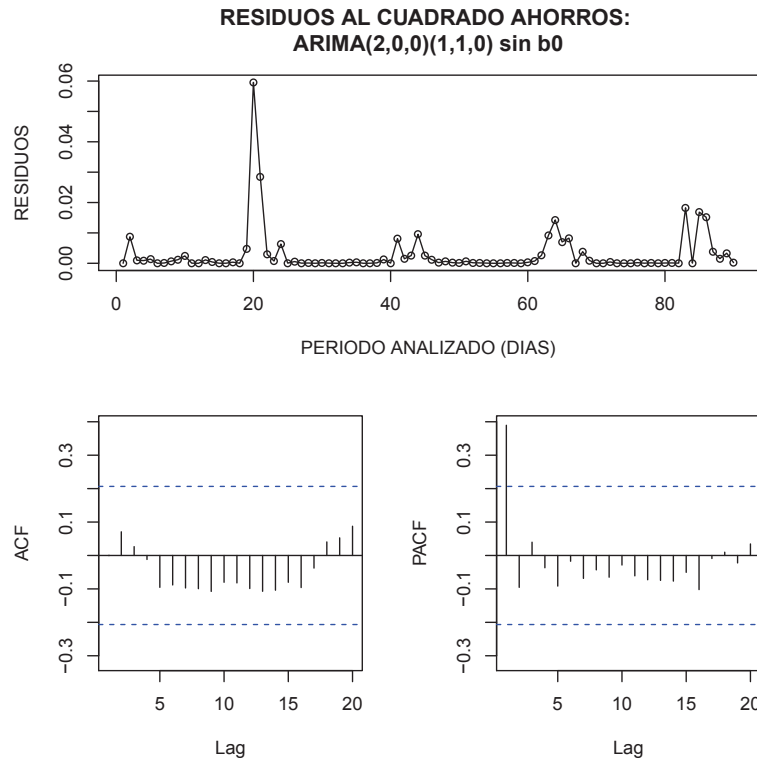

```
> tsdisplay(resid.ahorros3,
+ main="RESIDUOS AHORROS: ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.02484	-0.04993	11	-0.05058	-0.08358
2	-0.08076	-0.16436	12	-0.17328	-0.10454
3	-0.07927	-0.02982	13	-0.06917	-0.04970
4	0.00041	0.01738	14	-0.04128	-0.08591
5	-0.03409	-0.04693	15	-0.09451	0.05736
6	0.09457	-0.01279	16	-0.03900	-0.07370
7	-0.03805	0.03107	17	-0.00187	-0.08866
8	-0.07879	-0.05969	18	-0.09127	-0.18680
9	-0.12642	-0.13942	19	-0.24134	-0.10073
10	0.05448	-0.02484			

Tabla C.11: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros

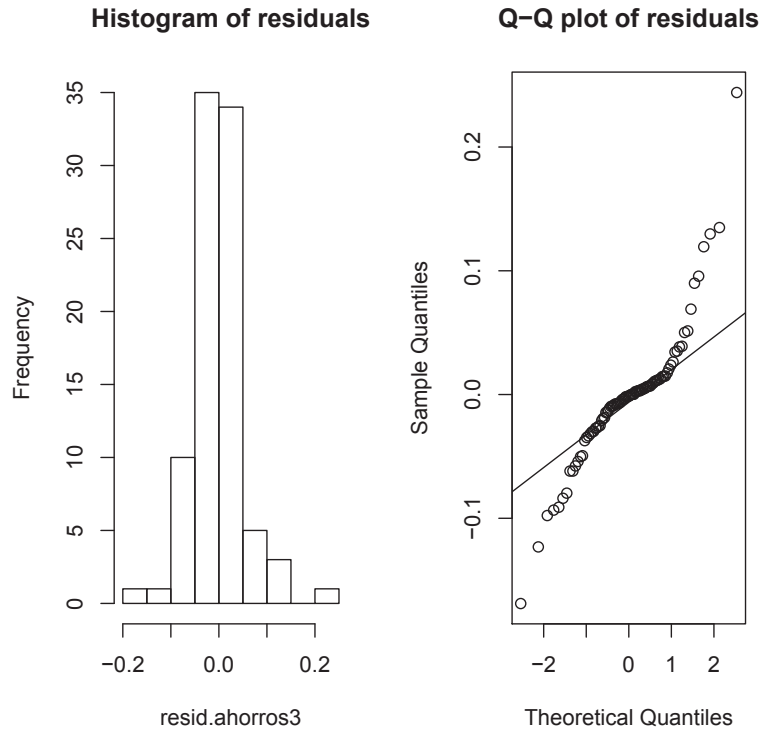
```
> tsdisplay(residsqr.ahorros3,
+ main="RESIDUOS AL CUADRADO AHORROS:
+ ARIMA(2,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.38953	0.07083	11	-0.09537	0.03974
2	0.02647	-0.01194	12	-0.03677	-0.09159
3	-0.09539	-0.08820	13	-0.01729	-0.06852
4	-0.09719	-0.09937	14	-0.04309	-0.06500
5	-0.10750	-0.08021	15	-0.02857	-0.06097
6	-0.08208	-0.09891	16	-0.07267	-0.07446
7	-0.10718	-0.10387	17	-0.07671	-0.05046
8	-0.08023	-0.09598	18	-0.10208	-0.00900
9	-0.03772	0.04052	19	0.00985	-0.02231
10	0.05274	0.38953			

Tabla C.12: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos ahorros

```
> par(mfrow=c(1,2))
> hist(resid.ahorros3,main="Histogram of residuals")
> qqnorm(resid.ahorros3,main="Q-Q plot of residuals")
> qqline(resid.ahorros3)
```



```
> shapiro.test(resid.ahorros3)
```

Shapiro-Wilk normality test

W = 0.8751, p-value = 3.659e-07

```
> x3 <- resid.ahorros3
> y3 <- fitdistr(x3, "normal")$estimate
> ksy3 <-ks.test(x3, pnorm, mean=y3[1], sd=y3[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1871, p-value = 0.003136

alternative hypothesis: two-sided

```
> ady3 <- ad.test(x3, pnorm, mean=y3[1], sd=y3[2])
```

Anderson-Darling GoF Test

AD = 3.831, p-value = 0.0106

alternative hypothesis: NA

C.4. MODELO 4: Arima(2,0,0)(2,1,0) sin b0

```
> ar.ahorros4 <- Arima(ts.ahorros, order=c(2,0,0),  
+                      seasonal=list(order=c(2,1,0)),  
+                      include.mean=FALSE,  
+                      include.constant=FALSE)  
> resid.ahorros4<-ar.ahorros4$residuals  
> resid sqr.ahorros4<-resid.ahorros4*resid.ahorros4
```

Series: ts.ahorros ARIMA(2,0,0)

Coefficients:

	ar1	ar2	sar1	sar2
	-0.2135	-0.0879	-0.2135	-0.0879
s.e.	0.0331	0.0884	0.0331	0.0884

sigma^2 estimated as 0.003096: log likelihood=130.72

AIC=-251.43 AICc=-250.71 BIC=-238.99

```
> fit4<-fitted.values(ar.ahorros4)
```

```
> grafpred.ahorros4<-cbind(ts.ahorros[-90],fit4[-1])  
> ts.plot(grafpred.ahorros4,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="DEPOSITOS AHORROS REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.8616	11	0.7189
2	0.0632	12	0.7815
3	0.1119	13	0.8376
4	0.1636	14	0.8802
5	0.2431	15	0.9010
6	0.3386	16	0.9053
7	0.4392	17	0.8006
8	0.5219	18	0.8380
9	0.6069	19	0.8765
10	0.6392		

Tabla C.13: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(2,0,0)(2,1,0)

```


> box2.ahorros4<-numeric()
> for (i in 1:20)
+   box2.ahorros4 <- c(box2.ahorros4,
+                     round(Box.test(residsqr.ahorros4,
+                                   lag=i)$p.value,4))
> mtestbox2.ahorros4 <- matrix(box2.ahorros4[-1],
+                               nrow=19,ncol=1,
+                               dimnames=list(c(),c("p-valor")))

```

Retardo	p-valor	Retardo	p-valor
1	0.0004	11	0.0232
2	0.0012	12	0.0265
3	0.0021	13	0.0293
4	0.0031	14	0.0326
5	0.0047	15	0.0377
6	0.0062	16	0.0509
7	0.0083	17	0.0671
8	0.0104	18	0.0839
9	0.0146	19	0.0893
10	0.0192		

Tabla C.14: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(2,0,0)(2,1,0)


```
> tsdisplay(resid.ahorros4,
+ main="RESIDUOS AHORROS: ARIMA(2,0,0)(2,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.01402	-0.05580	11	-0.05601	-0.28127
2	-0.27872	-0.04784	12	-0.06936	-0.11117
3	-0.06443	0.02645	13	-0.07602	-0.05370
4	0.00202	0.01018	14	-0.05693	-0.08578
5	-0.04470	-0.03378	15	-0.08001	0.04719
6	0.08082	0.00015	16	-0.04966	-0.07000
7	-0.02848	0.01097	17	0.02469	-0.05247
8	-0.02410	-0.06155	18	-0.09807	-0.11906
9	-0.08636	-0.17908	19	-0.28279	-0.10984
10	0.04276	-0.01402			

Tabla C.15: Autocorrelación y Autocorrelación Parcial: Residuos, serie de depósitos ahorros

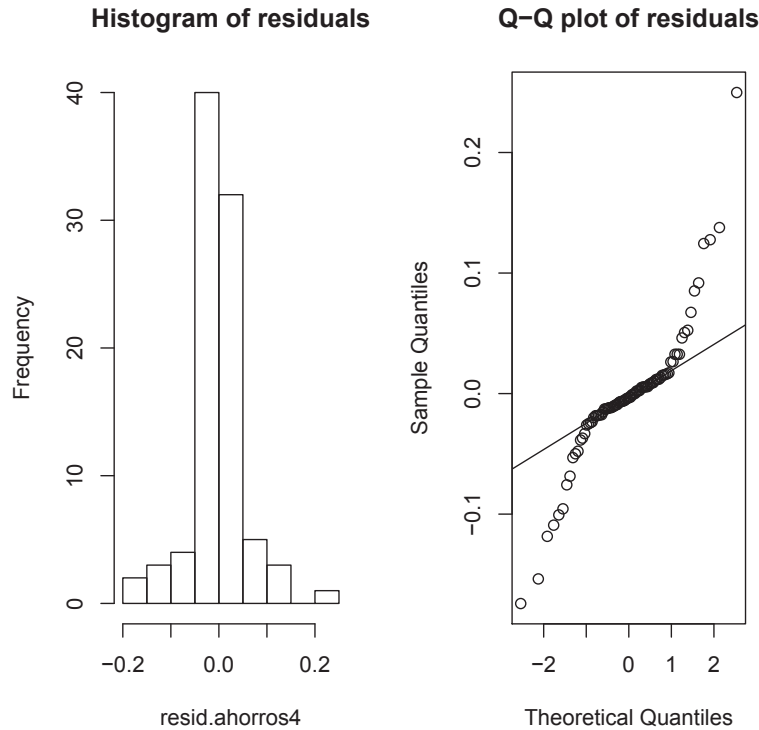
```
> tsdisplay(residsqr.ahorros4,
+ main="RESIDUOS AL CUADRADO AHORROS:
+ ARIMA(2,0,0)(2,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.40744	0.09455	11	-0.08569	0.04718
2	0.04597	-0.10062	12	-0.15773	-0.00277
3	-0.10672	-0.09719	13	-0.06288	-0.03912
4	-0.10453	-0.09984	14	-0.06204	-0.05990
5	-0.10362	-0.07728	15	-0.02891	-0.07215
6	-0.08408	-0.09643	16	-0.06721	-0.08516
7	-0.10323	-0.10707	17	-0.07596	-0.08570
8	-0.10420	-0.09448	18	-0.08254	-0.03573
9	-0.04265	0.04309	19	0.01642	-0.03625
10	0.05726	0.40744			

Tabla C.16: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie de depósitos ahorros


```
> par(mfrow=c(1,2))
> hist(resid.ahorros4,main="Histogram of residuals")
> qqnorm(resid.ahorros4,main="Q-Q plot of residuals")
> qqline(resid.ahorros4)
```



```
> shapiro.test(resid.ahorros4)
```

Shapiro-Wilk normality test

W = 0.8498, p-value = 4.158e-08

```
> x4 <- resid.ahorros4
> y4 <- fitdistr(x4, "normal")$estimate
> ksy4 <-ks.test(x4, pnorm, mean=y4[1], sd=y4[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1984, p-value = 0.001396

alternative hypothesis: two-sided

```
> ady4 <- ad.test(x4, pnorm, mean=y4[1], sd=y4[2])
```

Anderson-Darling GoF Test

AD = 4.9832, p-value = 0.002941

alternative hypothesis: NA

C.5. MODELO 5: Arima(1,0,0)(0,0,0) con b0 (log ahorros)

```
> ar.ahorros5 <- Arima(log(ts.ahorros), order=c(1,0,0),  
+                      seasonal=list(order=c(0,0,0)),  
+                      include.mean=TRUE,  
+                      include.constant=TRUE)  
> resid.ahorros5<-ar.ahorros5$residuals  
> residsq.ahorros5<-resid.ahorros5*resid.ahorros5
```

Series: log(ts.ahorros)

ARIMA(1,0,0) with non-zero mean

Coefficients:

	ar1	intercept
	0.3657	-2.7954
s.e.	0.1000	0.0759

sigma^2 estimated as 0.211: log likelihood=-57.77

AIC=121.53 AICc=121.81 BIC=129.03

```
> fit5<-fitted.values(ar.ahorros5)
```

```
> grafpred.ahorros5<-cbind(log(ts.ahorros)[-90],fit5[-1])  
> ts.plot(grafpred.ahorros5,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS AHORROS REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.9503	11	0.7953
2	0.3327	12	0.8381
3	0.4859	13	0.8794
4	0.6210	14	0.9120
5	0.7382	15	0.9165
6	0.8300	16	0.9236
7	0.8948	17	0.9446
8	0.7005	18	0.9616
9	0.7640	19	0.9733
10	0.8051		


Tabla C.17: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)

```
> box2.ahorros5<-numeric()
> for (i in 1:20)
+   box2.ahorros5 <- c(box2.ahorros5,
+                       round(Box.test(residsqr.ahorros5,
+                                       lag=i)$p.value,4))
> mtestbox2.ahorros5 <- matrix(box2.ahorros5[-1],
+                               nrow=19,ncol=1,
+                               dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.0214	11	0.0412
2	0.0201	12	0.0386
3	0.0250	13	0.0318
4	0.0268	14	0.0283
5	0.0258	15	0.0357
6	0.0270	16	0.0452
7	0.0260	17	0.0588
8	0.0309	18	0.0141
9	0.0400	19	0.0087
10	0.0440		

Tabla C.18: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)


```
> tsdisplay(resid.ahorros5,
+ main="RESIDUOS AHORROS: ARIMA(1,0,0)(0,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.00225	0.03357	11	0.03357	-0.19176
2	-0.19169	0.02070	12	0.02076	-0.01564
3	-0.02758	0.01729	13	-0.02133	0.01836
4	0.00833	0.00853	14	-0.00031	-0.18535
5	-0.17742	-0.04667	15	-0.04219	0.07984
6	0.06146	-0.10243	16	-0.18392	-0.06782
7	-0.04882	-0.03369	17	0.00282	-0.11145
8	-0.03255	-0.08455	18	-0.11311	-0.08793
9	-0.07938	-0.03226	19	-0.12187	-0.05450
10	0.02075	-0.00225			

Tabla C.19: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos ahorros

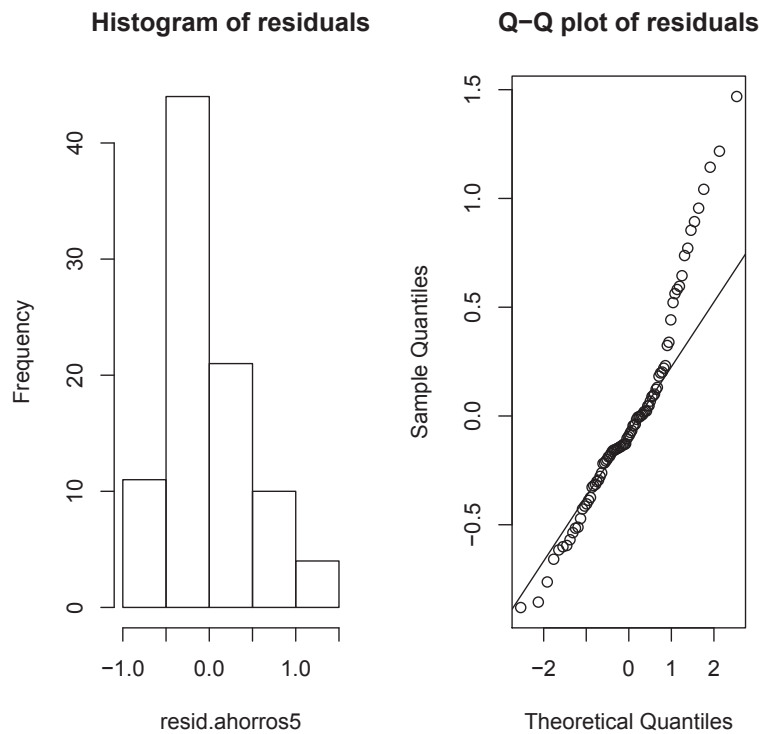
```
> tsdisplay(residsqr.ahorros5,
+ main="RESIDUOS AL CUADRADO AHORROS:
+ ARIMA(1,0,0)(0,0,0) con b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.24264	0.16293	11	0.11057	0.09908
2	0.15409	-0.12116	12	-0.20782	-0.10415
3	-0.12980	-0.13769	13	-0.07420	-0.00642
4	-0.12610	-0.13426	14	-0.07800	-0.05746
5	-0.10400	-0.08339	15	-0.06099	-0.08693
6	-0.10932	-0.13280	16	-0.12834	-0.11797
7	-0.13262	-0.14980	17	-0.13198	-0.12698
8	-0.13994	-0.07514	18	-0.08745	-0.12626
9	-0.06809	-0.05201	19	-0.15505	0.21707
10	0.27383	0.24264			

Tabla C.20: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos ahorros

```
> par(mfrow=c(1,2))
> hist(resid.ahorros5,main="Histogram of residuals")
> qqnorm(resid.ahorros5,main="Q-Q plot of residuals")
> qqline(resid.ahorros5)
```



```
> shapiro.test(resid.ahorros5)
```

Shapiro-Wilk normality test

W = 0.9328, p-value = 0.0001675

```
> x5 <- resid.ahorros5
> y5 <- fitdistr(x5, "normal")$estimate
> ksy5 <-ks.test(x5, pnorm, mean=y5[1], sd=y5[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1429, p-value = 0.04563

alternative hypothesis: two-sided

```
> ady5 <- ad.test(x5, pnorm, mean=y5[1], sd=y5[2])
```

Anderson-Darling GoF Test

AD = 2.2385, p-value = 0.06832

alternative hypothesis: NA

C.6. MODELO 6: Arima(1,0,0)(0,0,0) sin b0 (log ahorros)

```
> ar.ahorros6 <- Arima(log(ts.ahorros), order=c(1,0,0),  
+                      seasonal=list(order=c(0,0,0)),  
+                      include.mean=FALSE,  
+                      include.constant=FALSE)  
> resid.ahorros6<-ar.ahorros6$residuals  
> resid sqr.ahorros6<-resid.ahorros6*resid.ahorros6
```

Series: log(ts.ahorros)

ARIMA(1,0,0) with zero mean

Coefficients:

```
          ar1  
          0.9790  
s.e.      0.0169
```

sigma² estimated as 0.3025: log likelihood=-75.48

AIC=154.97 AICc=155.1 BIC=159.97

```
> fit6<-fitted.values(ar.ahorros6)
```

```
> grafpred.ahorros6<-cbind(log(ts.ahorros)[-90],fit6[-1])  
> ts.plot(grafpred.ahorros6,col=c("blue","red"), lty=1:2,  
+        xlab="PERIODO ANALIZADO (DIAS)",  
+        ylab="PORCENTAJE DE RETIRO",  
+        main="LOGARITMO DEPOSITOS AHORROS REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.0370	11	0.1793
2	0.0080	12	0.2325
3	0.0153	13	0.2909
4	0.0303	14	0.3558
5	0.0535	15	0.4239
6	0.0873	16	0.4730
7	0.1221	17	0.5144
8	0.1160	18	0.5648
9	0.1646	19	0.6277
10	0.1469		


Tabla C.21: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(0,0,0)

```
> box2.ahorros6<-numeric()
> for (i in 1:20)
+   box2.ahorros6 <- c(box2.ahorros6,
+                       round(Box.test(residsqr.ahorros6,
+                                       lag=i)$p.value,4))
> mtestbox2.ahorros6 <- matrix(box2.ahorros6[-1],
+                               nrow=19,ncol=1,
+                               dimnames=list(c(),c("p-valor")))
```

Retardo	p-valor	Retardo	p-valor
1	0.5687	11	0.7220
2	0.4503	12	0.6778
3	0.5953	13	0.7227
4	0.6327	14	0.7156
5	0.6576	15	0.7264
6	0.7042	16	0.7846
7	0.7037	17	0.8202
8	0.7037	18	0.8089
9	0.7363	19	0.7969
10	0.8076		

Tabla C.22: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(0,0,0)


```
> tsdisplay(resid.ahorros6,
+ main="RESIDUOS AHORROS: ARIMA(1,0,0)(0,0,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.26973	-0.02306	11	-0.10333	-0.30064
2	-0.24106	0.07245	12	-0.11063	-0.10641
3	-0.02470	0.02431	13	-0.10514	-0.03316
4	0.01568	0.05636	14	0.02959	-0.13081
5	-0.12773	-0.00835	15	-0.09174	0.11730
6	0.13580	-0.06822	16	-0.07314	-0.06673
7	-0.02316	0.02595	17	0.06055	-0.00992
8	0.01737	-0.01476	18	-0.02090	-0.03276
9	-0.05807	-0.06673	19	-0.15554	-0.21997
10	-0.05202	-0.26973			

Tabla C.23: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos ahorros

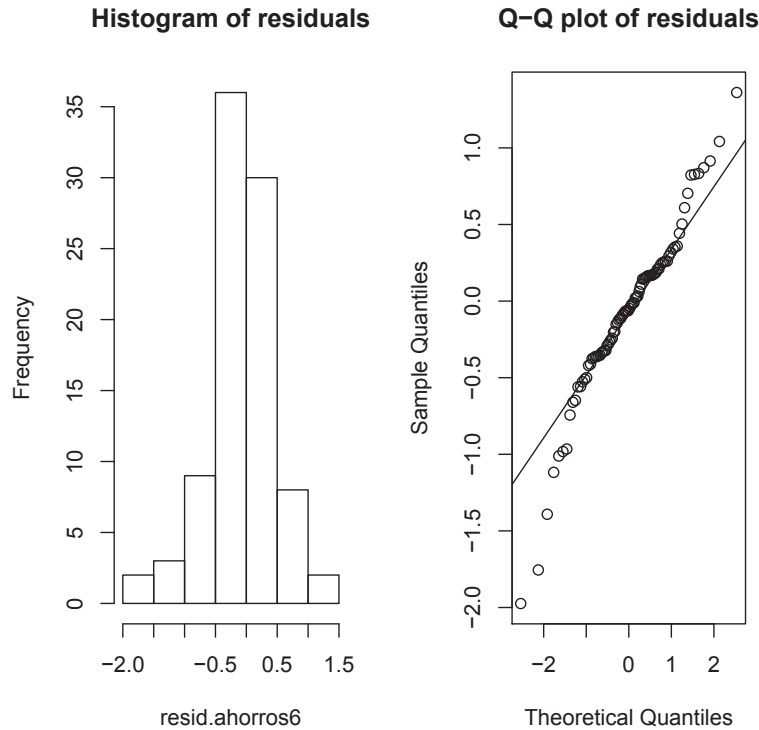
```
> tsdisplay(residsqr.ahorros6,
+ main="RESIDUOS AL CUADRADO AHORROS:
+ ARIMA(1,0,0)(0,0,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.09971	0.05099	11	0.04146	0.12206
2	0.12964	-0.03927	12	-0.06644	-0.08839
3	-0.08552	-0.08836	13	-0.08728	-0.03987
4	-0.07420	-0.09761	14	-0.06288	-0.06802
5	-0.09791	-0.07654	15	-0.06041	0.00768
6	-0.01063	-0.14454	16	-0.15021	-0.12625
7	-0.12567	-0.06072	17	-0.08055	-0.09940
8	-0.10448	-0.09080	18	-0.10467	-0.04045
9	0.00142	0.05280	19	-0.00036	0.05293
10	0.10818	0.09971			

Tabla C.24: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos ahorros

```
> par(mfrow=c(1,2))
> hist(resid.ahorros6,main="Histogram of residuals")
> qqnorm(resid.ahorros6,main="Q-Q plot of residuals")
> qqline(resid.ahorros6)
```



```
> shapiro.test(resid.ahorros6)
```

Shapiro-Wilk normality test

W = 0.9548, p-value = 0.003357

```
> x6 <- resid.ahorros6
> y6 <- fitdistr(x6, "normal")$estimate
> ksy6 <-ks.test(x6, pnorm, mean=y6[1], sd=y6[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.1011, p-value = 0.2966

alternative hypothesis: two-sided

```
> ady6 <- ad.test(x6, pnorm, mean=y6[1], sd=y6[2])
```

Anderson-Darling GoF Test

AD = 1.2203, p-value = 0.2599

alternative hypothesis: NA

C.7. MODELO 7: Arima(1,0,0)(1,1,0) sin b0 (log ahorros)

```
> ar.ahorros7 <- Arima(log(ts.ahorros), order=c(1,0,0),  
+                      seasonal=list(order=c(1,1,0)),  
+                      include.mean=FALSE,  
+                      include.constant=FALSE)  
> resid.ahorros7<-ar.ahorros7$residuals  
> residsq.ahorros7<-resid.ahorros7*resid.ahorros7
```

Series: log(ts.ahorros) ARIMA(1,0,0)

Coefficients:

	ar1	sar1
	-0.1540	-0.1540
s.e.	0.2484	0.2484

sigma^2 estimated as 0.2798: log likelihood=-69.65

AIC=145.31 AICc=145.59 BIC=152.77

```
> fit7<-fitted.values(ar.ahorros7)
```

```
> grafpred.ahorros7<-cbind(log(ts.ahorros)[-90],fit7[-1])  
> ts.plot(grafpred.ahorros7,col=c("blue","red"), lty=1:2,  
+        xlab ="PERIODO ANALIZADO (DIAS)",  
+        ylab ="PORCENTAJE DE RETIRO",  
+        main ="LOGARITMO DEPOSITOS AHORROS REAL VS ESTIMADA")
```


Retardo	p-valor	Retardo	p-valor
1	0.2240	11	0.2874
2	0.0173	12	0.3523
3	0.0378	13	0.4220
4	0.0707	14	0.4946
5	0.1132	15	0.5578
6	0.1621	16	0.5736
7	0.2253	17	0.5823
8	0.1884	18	0.6205
9	0.2550	19	0.6594
10	0.2317		

Tabla C.25: Prueba estadística de Box Pierce - Ljung Box: Residuos del modelo ARIMA(1,0,0)(1,1,0)

```


> box2.ahorros7<-numeric()
> for (i in 1:20)
+   box2.ahorros7 <- c(box2.ahorros7,
+                     round(Box.test(residsqr.ahorros7,
+                                   lag=i)$p.value,4))
> mtestbox2.ahorros7 <- matrix(box2.ahorros7[-1],
+                               nrow=19,ncol=1,
+                               dimnames=list(c(),c("p-valor")))

```

Retardo	p-valor	Retardo	p-valor
1	0.0294	11	0.0595
2	0.0172	12	0.0467
3	0.0267	13	0.0449
4	0.0415	14	0.0407
5	0.0480	15	0.0406
6	0.0494	16	0.0552
7	0.0462	17	0.0728
8	0.0443	18	0.0762
9	0.0560	19	0.0513
10	0.0700		

Tabla C.26: Prueba estadística de Box Pierce - Ljung Box: Residuos al cuadrado del modelo ARIMA(1,0,0)(1,1,0)



```
> tsdisplay(resid.ahorros7,
+ main="RESIDUOS AHORROS: ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	-0.01499	-0.18173	11	-0.18199	-0.29805
2	-0.28217	-0.00719	12	-0.07492	-0.13610
3	-0.00546	0.03629	13	-0.09000	-0.01132
4	0.04878	0.03401	14	-0.01467	-0.17055
5	-0.14382	-0.00678	15	-0.02241	0.09138
6	0.13143	-0.04591	16	-0.13552	-0.01869
7	-0.03310	0.02723	17	0.05329	-0.04436
8	0.01948	-0.03924	18	-0.03446	-0.08156
9	-0.09150	-0.09676	19	-0.20148	-0.21433
10	-0.06672	-0.01499			

Tabla C.27: Autocorrelación y Autocorrelación Parcial: Residuos, serie logaritmo de depósitos ahorros

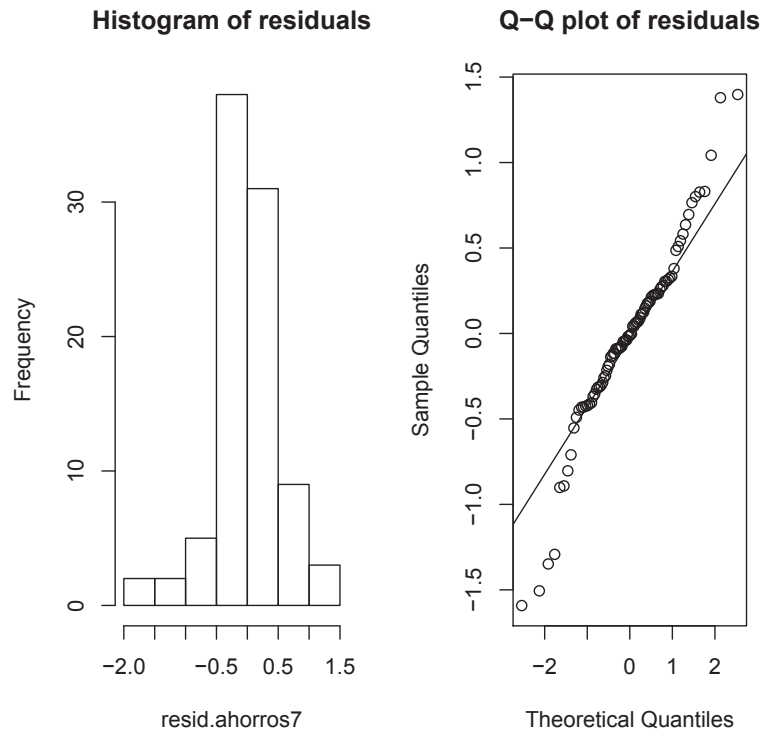
```
> tsdisplay(residsqr.ahorros7,
+ main="RESIDUOS AL CUADRADO AHORROS:
+ ARIMA(1,0,0)(1,1,0) sin b0",
+ ylab="RESIDUOS", xlab="PERIODO ANALIZADO (DIAS)", cex=0.8)
```



Retardo	ACF	PACF	Retardo	ACF	PACF
1	0.26124	0.10062	11	0.03475	0.16278
2	0.18593	-0.09576	12	-0.20253	-0.02195
3	-0.07875	-0.11326	13	-0.12196	-0.00693
4	-0.12477	-0.13489	14	-0.10789	-0.04447
5	-0.13148	-0.08440	15	-0.04867	-0.03542
6	-0.08117	-0.14507	16	-0.14849	-0.12997
7	-0.15549	-0.12777	17	-0.10715	-0.10327
8	-0.13671	-0.12136	18	-0.12305	0.03811
9	0.03686	0.03935	19	-0.05342	0.04787
10	0.10809	0.26124			

Tabla C.28: Autocorrelación y Autocorrelación Parcial: Residuos al cuadrado, serie logaritmo de depósitos ahorros

```
> par(mfrow=c(1,2))
> hist(resid.ahorros7,main="Histogram of residuals")
> qqnorm(resid.ahorros7,main="Q-Q plot of residuals")
> qqline(resid.ahorros7)
```



```
> shapiro.test(resid.ahorros7)
```

Shapiro-Wilk normality test

W = 0.9576, p-value = 0.005088

```
> x7 <- resid.ahorros7
> y7 <- fitdistr(x7, "normal")$estimate
> ksy7 <-ks.test(x7, pnorm, mean=y7[1], sd=y7[2])
```

One-sample Kolmogorov-Smirnov test

D = 0.0975, p-value = 0.3368

alternative hypothesis: two-sided

```
> ady7 <- ad.test(x7, pnorm, mean=y7[1], sd=y7[2])
```

Anderson-Darling GoF Test

AD = 1.2303, p-value = 0.2562

alternative hypothesis: NA

Anexo D

ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA CADA SERIE DE DEPÓSITOS ANALIZADA PARA SU RESPECTIVA CÓPULA

D.1. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA DE GUMBEL

```
> media.gumbel <- mean(sim.gumbel[,1])
> desvest.gumbel <- sd(sim.gumbel[,1])

> corriente.estim.gumbel <- rnorm(90*10000,mean=media.gumbel,
+                               sd=1.644854*desvest.gumbel)
> mcorriente.estim.gumbel <- matrix(corriente.estim.gumbel,
+                                   nrow=90,ncol=10000)
> corriente.arma.gumbel <- function(mcorriente.estim.gumbel)
+                               {ar.corriente$coef[[1]]*
+                               log(corriente)+
+                               ar.corriente$coef[[2]]+
+                               mcorriente.estim.gumbel}
> corriente.total.gumbel <- apply(mcorriente.estim.gumbel, 2,
+                                 corriente.arma.gumbel)

> corriente.gumbel <- exp(corriente.total.gumbel)
> corriente.gumbel.media <- apply(corriente.gumbel,2,mean)

> corriente.gumbel.max <- max(corriente.gumbel.media)
> corriente.gumbel.mean <- mean(corriente.gumbel.media)
```

```
> corriente.gumbel.mediana <- quantile(corriente.gumbel.media,  
+                                     0.5)[[1]]  
> corriente.gumbel.var95 <- quantile(corriente.gumbel.media,  
+                                     0.95)[[1]]
```

D.2. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA DE FRANK

```
> media.frank <- mean(sim.frank[,1])  
> desvest.frank <- sd(sim.frank[,1])  
  
> corriente.estim.frank <- rnorm(90*10000,mean=media.frank,  
+                               sd=1.644854*desvest.frank)  
> mcorriente.estim.frank <- matrix(corriente.estim.frank,  
+                                  nrow=90,ncol=10000)  
> corriente.arma.frank <- function(mcorriente.estim.frank)  
+                               {ar.corriente$coef[[1]]*  
+                               log(corriente)+  
+                               ar.corriente$coef[[2]]+  
+                               mcorriente.estim.frank}  
> corriente.total.frank <- apply(mcorriente.estim.frank,2,  
+                               corriente.arma.frank)  
  
> corriente.frank<-exp(corriente.total.frank)  
> corriente.frank.media <- apply(corriente.frank, 2, mean)  
  
> corriente.frank.max <-max(corriente.frank.media)  
> corriente.frank.mean <- mean(corriente.frank.media)  
> corriente.frank.mediana <- quantile(corriente.frank.media,  
+                                     0.5)[[1]]  
> corriente.frank.var95 <- quantile(corriente.frank.media,  
+                                     0.95)[[1]]
```

D.3. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA NORMAL

```
> media.normal <- mean(sim.normal[,1])
> desvest.normal <- sd(sim.normal[,1])

> corriente.estim.normal <- rnorm(90*10000,mean=media.normal,
+                               sd=1.644854*desvest.normal)
> mcorriente.estim.normal <- matrix(corriente.estim.normal,
+                                   nrow=90,ncol=10000)
> corriente.arma.normal <- function(mcorriente.estim.normal)
+                               {ar.corriente$coef[[1]]*
+                               log(corriente)+
+                               ar.corriente$coef[[2]]+
+                               mcorriente.estim.normal}
> corriente.total.normal <- apply(mcorriente.estim.normal,2,
+                                 corriente.arma.normal)

> corriente.normal <- exp(corriente.total.normal)
> corriente.normal.media <- apply(corriente.normal,2,mean)

> corriente.normal.max <- max(corriente.normal.media)
> corriente.normal.mean <- mean(corriente.normal.media)
> corriente.normal.mediana <- quantile(corriente.normal.media,
+                                     0.5)[[1]]
> corriente.normal.var95 <- quantile(corriente.normal.media,
+                                     0.95)[[1]]
```

D.4. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS CORRIENTE CON LA CÓPULA t

```
> media.t <- mean(sim.t[,1])
> desvest.t <- sd(sim.t[,1])
```



```
+             ar.plazo$coef[[2]]+
+             mplazo.estim.gumbel}
> plazo.total.gumbel <- apply(mplazo.estim.gumbel,2,
+             plazo.arma.gumbel)

> plazo.gumbel <- exp(plazo.total.gumbel)
> plazo.gumbel.media <- apply(plazo.gumbel,2,
+             mean)

> plazo.gumbel.max <- max(plazo.gumbel.media)
> plazo.gumbel.mean <- mean(plazo.gumbel.media)
> plazo.gumbel.mediana <- quantile(plazo.gumbel.media,
+             0.5)[[1]]
> plazo.gumbel.var95 <- quantile(plazo.gumbel.media,
+             0.95)[[1]]
```

D.6. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS A PLAZO CON LA CÓPULA DE FRANK

```
> media.frank <- mean(sim.frank[,2])
> desvest.frank <- sd(sim.frank[,2])

> plazo.estim.frank <- rnorm(90*10000, mean=media.frank,
+             sd=1.644854*desvest.frank)
> mplazo.estim.frank <- matrix(plazo.estim.frank,
+             nrow=90,ncol=10000)
> plazo.arma.frank <- function(mplazo.estim.frank)
+             {ar.plazo$coef[[1]]*log(plazo)+
+             ar.plazo$coef[[2]]+
+             mplazo.estim.frank}
> plazo.total.frank <- apply(mplazo.estim.frank,2,
+             plazo.arma.frank)

> plazo.frank <- exp(plazo.total.frank)
> plazo.frank.media <- apply(plazo.frank,2,mean)
```

```
> plazo.frank.max <- max(plazo.frank.media)
> plazo.frank.mean <- mean(plazo.frank.media)
> plazo.frank.mediana <- quantile(plazo.frank.media,
+                               0.5)[[1]]
> plazo.frank.var95 <- quantile(plazo.frank.media,
+                               0.95)[[1]]
```

D.7. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS A PLAZO CON LA CÓPULA NORMAL

```
> media.normal <- mean(sim.normal[,2])
> desvest.normal <- sd(sim.normal[,2])

> plazo.estim.normal <- rnorm(90*10000,mean=media.normal,
+                             sd=1.644854*desvest.normal)
> mplazo.estim.normal <- matrix(plazo.estim.normal,
+                               nrow=90,ncol=10000)
> plazo.arma.normal <- function(mplazo.estim.normal)
+                             {ar.plazo$coef[[1]]*
+                             log(plazo)+
+                             ar.plazo$coef[[2]]+
+                             mplazo.estim.normal}
> plazo.total.normal <- apply(mplazo.estim.normal,2,
+                             plazo.arma.normal)

> plazo.normal <- exp(plazo.total.normal)
> plazo.normal.media <- apply(plazo.normal,2,mean)

> plazo.normal.max <- max(plazo.normal.media)
> plazo.normal.mean <- mean(plazo.normal.media)
> plazo.normal.mediana <- quantile(plazo.normal.media,
+                                  0.5)[[1]]
> plazo.normal.var95 <- quantile(plazo.normal.media,
+                                  0.95)[[1]]
```

D.8. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS A PLAZO CON LA CÓPULA t

```
> media.t <- mean(sim.t[,2])
> desvest.t <- sd(sim.t[,2])

> plazo.estim.t <- rnorm(90*10000,mean=media.t,
+                       sd=1.644854*desvest.t)
> mplazo.estim.t <- matrix(plazo.estim.t,
+                          nrow=90,ncol=10000)
> plazo.arma.t <- function(mplazo.estim.t)
+                       {ar.plazo$coef[[1]]*log(plazo)+
+                       ar.plazo$coef[[2]]+mplazo.estim.t}
> plazo.total.t <- apply(mplazo.estim.t,2,plazo.arma.t)

> plazo.t <- exp(plazo.total.t)
> plazo.t.media <- apply(plazo.t,2,mean)

> plazo.t.max <- max(plazo.t.media)
> plazo.t.mean <- mean(plazo.t.media)
> plazo.t.mediana <- quantile(plazo.t.media,0.5)[[1]]
> plazo.t.var95 <- quantile(plazo.t.media,0.95)[[1]]
```

D.9. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA DE GUMBEL

```
> media.gumbel <- mean(sim.gumbel[,3])
> desvest.gumbel <- sd(sim.gumbel[,3])

> ahorros.estim.gumbel <- rnorm(86*10000,mean=media.gumbel,
+                              sd=1.644854*desvest.gumbel)
> mahorros.estim.gumbel<-matrix(ahorros.estim.gumbel,
+                               nrow=86,ncol=10000)
> mahorros.estim.gumbel2<-mahorros.estim.gumbel*
```

```
+ mahorros.estim.gumbel
> x <- log(ahorros)
> xt_1 <- x[c(-1,-2,-3,-90)]
> xt_2 <- x[c(-1,-2,-89,-90)]
> xt_3 <- x[c(-1,-88,-89,-90)]
> xt_4 <- x[c(-87,-88,-89,-90)]
> ahorros.arma.gumbel <- function(mahorros.estim.gumbel)
+ {0.6383*xt_1 + 0.1399*xt_2 -
+ 0.1024*xt_3 + 0.3242*xt_4 +
+ mahorros.estim.gumbel}
> ahorros.total.gumbel <- apply(mahorros.estim.gumbel,2,
+ ahorros.arma.gumbel)

> ahorros.gumbel <- exp(ahorros.total.gumbel)
> ahorros.gumbel.media <- apply(ahorros.gumbel,2,mean)

> ahorros.gumbel.max <- max(ahorros.gumbel.media)
> ahorros.gumbel.mean <- mean(ahorros.gumbel.media)
> ahorros.gumbel.mediana <- quantile(ahorros.gumbel.media,
+ 0.5)[[1]]
> ahorros.gumbel.var95 <- quantile(ahorros.gumbel.media,
+ 0.95)[[1]]
```

D.10. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA DE FRANK

```
> media.frank <- mean(sim.frank[,3])
> desvest.frank <- sd(sim.frank[,3])

> ahorros.estim.frank <- rnorm(86*10000,mean=media.frank,
+ sd=1.644854*desvest.frank)
> mahorros.estim.frank <- matrix(ahorros.estim.frank,
+ nrow=86,ncol=10000)
> mahorros.estim.frank2 <- mahorros.estim.frank*
```

```
+ mahorros.estim.frank
> x <- log(ahorros)
> xt_1 <- x[c(-1,-2,-3,-90)]
> xt_2 <- x[c(-1,-2,-89,-90)]
> xt_3 <- x[c(-1,-88,-89,-90)]
> xt_4 <- x[c(-87,-88,-89,-90)]
> ahorros.arma.frank <- function(mahorros.estim.frank)
+ {0.6383*xt_1 + 0.1399*xt_2 -
+ 0.1024*xt_3 + 0.3242*xt_4 +
+ mahorros.estim.frank}
> ahorros.total.frank <- apply(mahorros.estim.frank, 2,
+ ahorros.arma.frank)

> ahorros.frank <- exp(ahorros.total.frank)
> ahorros.frank.media <- apply(ahorros.frank,2,mean)

> ahorros.frank.max <- max(ahorros.frank.media)
> ahorros.frank.mean <- mean(ahorros.frank.media)
> ahorros.frank.mediana <- quantile(ahorros.frank.media,
+ 0.5)[[1]]
> ahorros.frank.var95 <- quantile(ahorros.frank.media,
+ 0.95)[[1]]
```

D.11. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA NORMAL

```
> media.normal <- mean(sim.normal[,3])
> desvest.normal <- sd(sim.normal[,3])

> ahorros.estim.normal <- rnorm(86*10000,mean=media.normal,
+ sd=1.644854*desvest.normal)
> mahorros.estim.normal <- matrix(ahorros.estim.normal,
+ nrow=86,ncol=10000)
> mahorros.estim.normal2 <- mahorros.estim.normal*
```

```

+                               mahorros.estim.normal
> x <- log(ahorros)
> xt_1 <- x[c(-1,-2,-3,-90)]
> xt_2 <- x[c(-1,-2,-89,-90)]
> xt_3 <- x[c(-1,-88,-89,-90)]
> xt_4 <- x[c(-87,-88,-89,-90)]
> ahorros.arma.normal <- function(mahorros.estim.normal)
+                               {0.6383*xt_1 + 0.1399*xt_2 -
+                               0.1024*xt_3 + 0.3242*xt_4 +
+                               mahorros.estim.normal}
> ahorros.total.normal <- apply(mahorros.estim.normal, 2,
+                               ahorros.arma.normal)

> ahorros.normal <- exp(ahorros.total.normal)
> ahorros.normal.media <- apply(ahorros.normal, 2, mean)

> ahorros.normal.max <- max(ahorros.normal.media)
> ahorros.normal.mean <- mean(ahorros.normal.media)
> ahorros.normal.mediana <- quantile(ahorros.normal.media,
+                                   0.5)[[1]]
> ahorros.normal.var95 <- quantile(ahorros.normal.media,
+                                   0.95)[[1]]

```

D.12. ESTIMACIÓN DEL PARÁMETRO DE RETIRO PARA LA SERIE DEPÓSITOS DE AHORROS CON LA CÓPULA t

```

> media.t <- mean(sim.t[,3])
> desvest.t <- sd(sim.t[,3])

> ahorros.estim.t <- rnorm(86*10000,mean=media.t,
+                          sd=1.644854*desvest.t)
> mahorros.estim.t <- matrix(ahorros.estim.t,
+                              nrow=86,ncol=10000)
> mahorros.estim.t2 <- mahorros.estim.t*
+                       mahorros.estim.t

```

```
> x <- log(ahorros)
> xt_1 <- x[c(-1,-2,-3,-90)]
> xt_2 <- x[c(-1,-2,-89,-90)]
> xt_3 <- x[c(-1,-88,-89,-90)]
> xt_4 <- x[c(-87,-88,-89,-90)]
> ahorros.arma.t <- function(mahorros.estim.t)
+       {0.6383*xt_1 + 0.1399*xt_2 -
+       0.1024*xt_3 + 0.3242*xt_4 +
+       mahorros.estim.t}
> ahorros.total.t <- apply(mahorros.estim.t, 2,
+       ahorros.arma.t)

> ahorros.t <- exp(ahorros.total.t)
> ahorros.t.media <- apply(ahorros.t,2,mean)

> ahorros.t.max <- max(ahorros.t.media)
> ahorros.t.mean <- mean(ahorros.t.media)
> ahorros.t.mediana <- quantile(ahorros.t.media,0.5)[[1]]
> ahorros.t.var95 <- quantile(ahorros.t.media,0.95)[[1]]
```

Anexo E

GLOSARIO DE TÉRMINOS

- **Modelo.-** Puede definirse como una representación simplificada de un sistema real o un proceso, con el que se pretende aumentar su comprensión, hacer predicciones y posiblemente ayudar a controlar el sistema.
- **Metodología de la Modelización.-** Se refiere a un conjunto de procedimientos sistemáticos basados en conocimiento acumulado cuyo objetivo es abordar y resolver problemas. Es una metodología, bien desarrollada en áreas de las Ciencias y la Ingeniería que han alcanzado cierta madurez.
- **Modelización.-** Es el proceso por el cual se establecen relaciones entre las entidades importantes de un sistema que se expresa en términos de metas, criterios de ejecución y restricciones que en conjunto constituyen el modelo.
- **Requerimiento Mínimo.-** Garantiza que el nivel de activos más líquidos, sea suficiente para cubrir una parte de los pasivos exigibles en el corto plazo, denominada parte volátil.
- **Fuente de Fondo.-** Son las captaciones de depósitos por parte de las instituciones financieras y forman parte del binomio de funciones fundamentales de la intermediación financiera (Captación - Colocación).
- **Simulación.-** Proceso que permite construir modelos informáticos que describen la parte esencial del comportamiento de un sistema de interés, así como diseñar y realizar experimentos con el modelo y extraer conclusiones de sus resultados para apoyar la toma de decisiones.

- **Pruebas retrospectivas (backtesting).**- Finalmente para comparar cualquier método, metodología o modelo estadístico es importante que se efectúen pruebas de desempeño con datos históricos y contrastarlos con los datos del presente.
- **Riesgo Financiero.**- Es la posibilidad de que se produzca un hecho generador de pérdidas que afecten el valor económico de las instituciones.
- **Riesgo de Liquidez.**- Es la contingencia de pérdida que se manifiesta por la incapacidad de la institución del sistema financiero para enfrentar una escasez de fondos y cumplir sus obligaciones; y, que determina la necesidad de conseguir recursos alternativos, o de realizar activos en condiciones desfavorables.
- **Índice Estructural de Liquidez.**- Relación observada entre los activos líquidos frente a los pasivos exigibles en el corto plazo, medida como el cociente entre ambos, y puede ser medido en dos niveles: primera línea y segunda línea; para lo cual también se distinguen los activos líquidos de primera línea y de segunda línea y pasivos exigibles de primera y segunda línea.
- **Parte Volátil o Volatilidad de los Depósitos.**- Está constituida por una porción de los pasivos con vencimiento incierto que puede ser exigida de forma aleatoria y otra porción de los mismos pasivos, exigible en el muy corto plazo de manera cierta y programada.
- **Volatilidad.**- Medida estadística de dispersión de la distribución esperada de los rendimientos de un activo; cuanto mayor es la variabilidad, mayor es la dispersión de la distribución de los rendimientos esperados y viceversa, cuantificados en un horizonte temporal determinado.
- **Cópulas.**- Son funciones que relacionan funciones de distribución multivariadas con sus correspondientes funciones marginales univariadas, funciones de distribución cuyos márgenes unidimensionales son uniformes, lo cual permite construir modelos que van más allá de los estándares en el análisis de dependencia entre variables estocásticas.

- **Liquidez Estructural.-** Parte de considerar la composición de activos y pasivos en una posición estática (saldos contables) a una fecha determinada y sobre la base de datos contables. Se definen los mayores depositantes, su composición y la evolución de sus depósitos.
- **Liquidez Contractual.-** Para determinar la exposición al riesgo de liquidez contractual se deberá analizar los vencimientos de los activos y pasivos distribuyéndolos en bandas de tiempo.
- **Liquidez Esperada.-** Es el resultado de la diferencia entre activos líquidos y pasivos inmediatos, en este análisis se deben construir escenarios sobre el comportamiento de ciertas cuentas, con lo que su vencimiento difiere del escenario contractual.
- **Liquidez Dinámica.-** En este análisis, a diferencia del anterior, se plantean crecimientos o decrecimientos en los saldos en las cuentas de los activos, pasivos y contingentes, considerando movimientos de dinero a futuro o nuevos proyectos a largo plazo.