



## Trabajo Fin de Grado

Desarrollo de un gemelo digital de una línea  
multietapa de fabricación de rodamientos

Development of a digital twin for a multi-stage  
bearing manufacturing line

Autor

Guillermo Pardos Moreno

Director

Juan José Aguilar Martín

Grado en Ingeniería de tecnologías industriales

Escuela de Ingeniería y Arquitectura

2024-2025



## RESUMEN

El trabajo de Fin de Grado descrito a continuación detalla el procedimiento para desarrollar y validar un Gemelo Digital (GD) mediante Machine Learning para una línea de producción multietapa de rodamientos de rodillos cónicos de doble hilera para camiones. Dirigido por el Dr. Juan José Aguilar Martín, se realiza en el departamento de Ingeniería de Diseño y Fabricación de la Escuela de Ingeniería y Arquitectura de la Universidad de Zaragoza.

Se plantea como objetivo final que este gemelo digital monitorice los procesos haciendo que en la zona de ensamblaje la emparejadora asocie los conos a sus aros correspondientes teniendo en cuenta las tolerancias de cada una. Asegurando así que todas las piezas que constituyen el rodamiento encajen a la primera y que no haya tiempos de espera que puedan empeorar la eficiencia del proceso. Con esto se consigue que la cadena de montaje tenga un mayor grado de control, mayor eficiencia y un mejor seguimiento de los datos de las piezas que se recogen en el datamatrix. Asimismo se logran reducir los costes de inventario y de espacio requerido en la zona de emparejado.

Inicialmente se ha trabajado con datos sintéticos para ver la influencia de las variables en la variable de salida. Además se ha analizado la relación que tienen unas variables con otras y se ha valorado la influencia de ruidos y de incertidumbres con respecto a la precisión del resultado final de las predicciones. Todo esto ha servido para extrapolar los resultados obtenidos al modelo con los datos reales y así entender mejor cómo funciona el modelo con sus variables.

Más adelante se ha trabajado con las diferentes partes del proceso por separado, primero la línea de los conos, después la de los aros y finalmente la de emparejado. Todas ellas componen el GD. Para cada una se han analizado las variables más influyentes en las variables de salida además de determinar qué modelos son los que mejor se ajustan a la realidad.

Finalmente, se ha trabajado con el gemelo digital cambiando ciertos parámetros con respecto al número de variables, métodos de emparejamiento y otros, con el objetivo de ver cuál es la forma más eficiente de realizar emparejamientos exitosos.

The Final Degree Project described below details the procedure for developing and validating a Digital Twin (DT) using Machine Learning for a multi-stage production line of double-row tapered roller bearings for trucks. Supervised by Dr. Juan José Aguilar Martín, this work is carried out in the Department of Design and Manufacturing Engineering at the School of Engineering and Architecture of the University of Zaragoza.

The ultimate goal is for this digital twin to monitor processes in such a way that, in the assembly area, the pairing system associates cones with their corresponding outer rings, taking into account the tolerances of each. This ensures that all components of the bearing fit correctly on the first attempt, avoiding delays that could decrease process efficiency. As a result, the assembly line achieves greater control, increased efficiency, and improved tracking of the data collected from each part via the datamatrix. Additionally, it helps to reduce inventory costs and the space required in the pairing area.

Initially, synthetic data was used to study the influence of variables on the output variable. The relationships between variables were analyzed, and the impact of noise and uncertainties on the final accuracy of predictions was evaluated. This preliminary analysis was essential for extrapolating the results obtained to the model with real data, improving the understanding of how the model functions with its variables.

Subsequently, the various parts of the process were addressed separately: first the outer ring line, then the cone line, and finally the pairing process. These components collectively form the DT. For each part, the most influential variables were analyzed, and the models that best fit reality were identified.

Finally, the digital twin was refined by modifying certain parameters, such as the number of variables, pairing methods, and others, to identify the most efficient approach for achieving successful pairings.

# TABLA DE CONTENIDO

<b>RESUMEN .....</b>	<b>2</b>
<b>INDICE DE FIGURAS .....</b>	<b>7</b>
<b>INDICE DE TABLAS .....</b>	<b>13</b>
<b>1. INTRODUCCIÓN .....</b>	<b>14</b>
<b>1.1 OBJETIVO .....</b>	<b>14</b>
<b>1.2 ESTRUCTURA .....</b>	<b>15</b>
<b>1.3 CONTENIDO DE LA MEMORIA.....</b>	<b>16</b>
<b>2. ESTADO DEL ARTE .....</b>	<b>17</b>
<b>2.1 REVISIÓN DE INVESTIGACIONES ANTERIORES.....</b>	<b>17</b>
<b>2.1.1 FABRICACIÓN DE LOS COMPONENTES (AROS Y CONOS) .....</b>	<b>17</b>
<b>2.2 EVOLUCIÓN DE LOS GEMELOS DIGITALES.....</b>	<b>18</b>
<b>2.2.1 CONTEXTO .....</b>	<b>19</b>
<b>2.2.2 FUTURO DE LOS GEMELOS DIGITALES: GD ACTUAL VS GD FUTURO .....</b>	<b>20</b>
<b>3. CONCEPTOS DE MACHINE LEARNING .....</b>	<b>21</b>
<b>3.1 DEFINICIÓN .....</b>	<b>21</b>
<b>3.2 HERRAMIENTAS DE LA TOOLBOX DE MATLAB UTILIZADAS .....</b>	<b>25</b>
<b>3.2.1 ENTRENAMIENTO.....</b>	<b>25</b>
<b>3.2.2 TEST .....</b>	<b>37</b>
<b>3.2.3 EXPLAIN .....</b>	<b>40</b>
<b>3.2.4 DEPENDENCIA PARCIAL.....</b>	<b>43</b>
<b>4. DESCRIPCIÓN DEL PROCESO DE FABRICACIÓN MULTITAPA .....</b>	<b>44</b>
<b>4.1 RODAMIENTOS.....</b>	<b>44</b>
<b>4.1.1 TIPO .....</b>	<b>44</b>
<b>4.2 PROCESO DE FABRICACIÓN .....</b>	<b>45</b>
<b>4.2.1 FASES PRINCIPALES DEL PROCESO .....</b>	<b>45</b>
<b>4.2.2 PROCESOS .....</b>	<b>47</b>
<b>4.2.3 FABRICACIÓN DE AROS.....</b>	<b>49</b>
<b>4.2.4 FABRICACIÓN DE CONOS.....</b>	<b>49</b>
<b>4.2.5 ENSAMBLAJE Y ALMACENAMIENTO .....</b>	<b>49</b>
<b>4.2.6 PRINCIPALES VARIABLES E INDICADORES PARA MONITORIZAR .....</b>	<b>52</b>
<b>4.2.7 MÉTODO DE CENTROS DE GRAVEDAD .....</b>	<b>53</b>
<b>4.2.8 RECOPILACIÓN DE DATOS .....</b>	<b>55</b>
<b>5. DISEÑO Y DESARROLLO DEL GEMELO DIGITAL.....</b>	<b>61</b>

<b>5.1 PRUEBAS CON DATOS SINTÉTICOS .....</b>	61
<b>5.1.1 ENTRENAMIENTO SIN RUIDO Y SIN VARIABLES ESPUREAS.....</b>	61
<b>5.1.2 ENTRENAMIENTO CON VARIABLES ESPURIAS .....</b>	64
<b>5.1.3 ENTRENAMIENTO SOLO CON RUIDO .....</b>	64
<b>5.1.4 ENTRENAMIENTO CON RUIDO Y VARIABLES ESPURIAS .....</b>	65
<b>5.1.5 OBSERVACIONES DE PRUEBAS CON DATOS SINTÉTICOS.....</b>	65
<b>5.2 CONOS.....</b>	66
<b>5.2.1 ANÁLISIS PREVIO DE VARIABLES DE CONOS.....</b>	66
<b>5.2.2 ENTRENAMIENTOS Y TESTEOS DE CONOS .....</b>	68
<b>5.2.3 PÉRDIDA DE PRECISIÓN SIN ENTRENAMIENTO.....</b>	71
<b>5.3 AROS .....</b>	73
<b>5.3.1 ANÁLISIS PREVIO DE VARIABLES DE AROS .....</b>	73
<b>5.3.2 ENTRENAMIENTO Y TESTEO DE AROS.....</b>	75
<b>5.4 SIMULACIÓN GLOBAL (GD CON DATOS ANTERIORES).....</b>	79
<b>5.4.1 CAMBIO EN LA ESTRATEGIA DE EMPAREJADO .....</b>	79
<b>5.4.2 CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25 .....</b>	82
<b>5.4.3 CAMBIO EN EL NÚMERO DE FACTORES.....</b>	83
<b>5.4.4 CAMBIO DE DISTRIBUCIÓN DE CONOS .....</b>	83
<b>5.5 GD CON LOS DATOS NUEVOS .....</b>	84
<b>5.5.1 CAMBIO EN LA ESTRATEGIA DE EMPAREJADO .....</b>	84
<b>5.5.2 CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25 .....</b>	87
<b>5.5.3 CAMBIO EN EL NÚMERO DE FACTORES.....</b>	87
<b>5.5.4 CAMBIO DE DISTRIBUCIÓN DE CONOS .....</b>	88
<b>6. ESTIMACIÓN ECONÓMICA Y PLANIFICACIÓN .....</b>	89
<b>7. CONCLUSIONES .....</b>	91
<b>8. BIBLIOGRAFÍA .....</b>	93
<b>9. ANEXOS .....</b>	95
<b>ANEXO 1 FABRICACIÓN DE AROS Y CONOS .....</b>	95
<b>AROS .....</b>	95
<b>CONOS.....</b>	99
<b>ENSAMBLAJE Y ALMACENAMIENTO .....</b>	107
<b>ANEXO 2 DATOS SINTÉTICOS.....</b>	110
<b>ANEXO 3 CONOS.....</b>	124
<b>ENTRENAMIENTO Y TEST POR CONOS .....</b>	126

<b>ENTRENAMIENTO Y TEST POR SEMANAS .....</b>	131
<b>ENTRENAMIENTO Y TEST POR DÍAS.....</b>	137
<b>ANEXO 4 AROS.....</b>	142
<b>ENTRENAMIENTO Y TEST POR MUELAS .....</b>	142
<b>ENTRENO Y TESTEO POR SEMANA Y POR DÍAS .....</b>	145
<b>ANEXO 5 GEMELO DIGITAL .....</b>	155
<b>GD CON DATOS DE PARTIDA.....</b>	155
<b>GD CON LOS DATOS NUEVOS .....</b>	181
<b>ANEXO 6 SCRIPTS .....</b>	203
<b>AROS .....</b>	203
<b>CONOS.....</b>	205
<b>SIMULACION GLOBAL GD ANTERIOR .....</b>	<b>;Error! Marcador no definido.</b>
<b>SIMULACION GLOBAL GD NUEVO .....</b>	209

# INDICE DE FIGURAS

Ilustración 1 métodos de aprendizaje para entrenar la computadora .....	22
Ilustración 2 método de clustering.....	23
Ilustración 3 diferentes métodos de análisis de datos mediante machine learning.....	24
Ilustración 4 ejemplos de modelos empleados en el análisis predictivo por machine learning en matlab .....	25
Ilustración 5 ejemplo de regresión lineal multivariante que muestra cómo predecir las estimaciones de gripe en 9 regiones de EE. UU. (variables de respuesta, $Y_i$ ), basadas en la semana del año (variable predictora, $X$ ).....	27
Ilustración 6 ejemplo de regresión lineal múltiple multivariante que calcula las MPG en ciudad y autopista (como variables de respuesta, $Y_1$ y $Y_2$ ) a partir de tres variables: distancia entre ejes, peso en vacío y tipo de combustible (variables predictoras, $X_1$ , $X_2$ y $X_3$ ).....	27
Ilustración 7 gráfica típica de árboles de ensamble.....	28
Ilustración 8 gráfica típica de árboles de decisión .....	29
Ilustración 9 gráfica típica de procesos gaussianos .....	30
Ilustración 10 esquema de redes neuronales.....	31
Ilustración 11 hiperplano en el modelo SVM .....	32
Ilustración 12 gráfica que muestra los valores reales, las predicciones y los errores de entrenamiento cometidos.....	34
Ilustración 13 resumen de los resultados tras realizar entrenamientos y testeos .....	35
Ilustración 14 gráfica de observaciones frente a la predicción perfecta.....	35
Ilustración 15 gráfica de residuos rmse con respecto a la respuesta real.....	36
Ilustración 16 gráfica de residuos rmse con respecto a las predicciones .....	37
Ilustración 17 gráfica de observaciones frente a la predicción perfecta (test).....	38
Ilustración 18 gráfica de residuos rmse con respecto a la respuesta real (Test) .....	38
Ilustración 19 gráfica de residuos rmse con respecto a las predicciones .....	39
Ilustración 20 gráfica de respuesta en función de las variables del modelo .....	40
Ilustración 21 gráfica del shapley intervencional .....	41
Ilustración 22 gráfica del shapley intervencional .....	42
Ilustración 23 .....	43
Ilustración 24 gráfica de dependencia parcial .....	43
Ilustración 25 rodamientos de rodillos cónicos de doble fila (o bicónico).....	45
Ilustración 26 rodamiento de rodillos cónicos de doble fila (o bicónico) .....	45
Ilustración 27 esquema resumido de la planta de fabricación de rodamientos .....	46
Ilustración 28 línea de producción completa con sus 3 estaciones principales .....	47
Ilustración 29 procesos iniciales de fabricación dde aros y conos.....	48
Ilustración 30 procesos de fabricación de aros y conos .....	48
Ilustración 31 desviaciones problemáticas de la sonda al medir el diámetro de la valona.....	50
Ilustración 32 clasificación de los conos en 20 familias de 4 $\mu\text{m}$ en función de $Ti_{\text{inversa}}$ . La familia 0 corresponde a los conos fuera de los límites de tolerancia. ....	51
Ilustración 33 clasificación de los aros en 20 familias de 8 $\mu\text{m}$ en función de la distancia entre pistas. La familia 0 corresponde a los conos fuera de los límites de tolerancia. ....	51
Ilustración 34 (a) distribución típica de los IR en la máquina de ensamblaje. Cada familia cubre un rango de 4 $\mu\text{m}$ , lo que lleva a una tolerancia de 80 $\mu\text{m}$ . (b)	

Centros de gravedad calculados para cada grupo encontrado en las distribuciones de IR (líneas continuas) y familia de OR propuesta basada en los CG de los IR (línea punteada).....	53
Ilustración 35 centros de gravedad y distribución de conos propuestas .....	54
Ilustración 36 esquema de comunicación y flujo de datos desde la línea de producción hasta el gemelo digital (GD).....	58
Ilustración 37 arquitectura global del gemelo digital (GD) y su integración en la línea de producción. En líneas punteadas y continuas se representan los procesos físicos y digitales, respectivamente. Resultados en azul. Estaciones y procesos principales modelados en naranja. .....	59
Ilustración 38 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	62
Ilustración 39 análisis intervencional sin interacciones entre variables .....	63
Ilustración 40 análisis condicional con interacciones entre variables .....	63
Ilustración 41 gráfica mostrando la influencia del ruido .....	66
Ilustración 42 gráfica del comportamiento de la posición fin de trabajo Z.....	67
Ilustración 43 gráfica del comportamiento de la posición fin de trabajo X.....	67
Ilustración 44 gráfica del comportamiento de la suma de correcciones eje X.....	67
Ilustración 45 gráfica del comportamiento de la suma de correcciones eje Z.....	68
Ilustración 46 gráfica del comportamiento del diámetro actual de muela.....	68
Ilustración 47 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	70
Ilustración 48 resumen comparativo de entrenamientos y test semanales.....	70
Ilustración 49 resumen comparativo de entrenamientos y test diarios .....	71
Ilustración 50 gráfica de la influencia de entrenamientos periódicos en testeos frente a entrenamiento único de un intervalo .....	72
Ilustración 51 gráfica del comportamiento de la compensación de diamantado .....	73
Ilustración 52 gráfica del comportamiento de la memoria de compensación de diámetro .....	73
Ilustración 53 gráfica del comportamiento de la memoria de compensación de rectificado .....	74
Ilustración 54 gráfica del comportamiento del diámetro actual de muela.....	74
Ilustración 55 gráfica del comportamiento de la posición x de rectificado.....	74
Ilustración 56 gráfica de respuesta de los resultados reales y de las predicciones .....	76
Ilustración 57 resumen comparativo de entrenamientos y test por muelas .....	76
Ilustración 58 resumen comparativo de entrenamientos y test diarios .....	77
Ilustración 59 resumen comparativo de entrenamientos y test semanales.....	77
Ilustración 60 información general para el gemelo digital.....	79
Ilustración 61 distribución de conos con su familia y variables de control .....	80
Ilustración 62 resumen de distribución de aros en la simulación.....	81
Ilustración 63 resultado de la simulación.....	81
Ilustración 64 gráfica resumen de cambios de estrategias de emparejamiento.....	82
Ilustración 65 gráfica resumen del cambio de número de factores.....	83
Ilustración 66 gráfica resumen de los resultados en función de la distribución de conos .....	84
Ilustración 67 información general para el gemelo digital (datos nuevos).....	85
Ilustración 68 resumen de distribución de aros en la simulación .....	85
Ilustración 69 distribución de conos con su familia y variables de control .....	86
Ilustración 70 resultado de la simulación con datos nuevos .....	86
Ilustración 71 gráfica resumen de cambios en la estrategia de emparejamiento .....	87
Ilustración 72 gráfica resumen de cambios en el número de factores .....	88

Ilustración 73 gráfica resumen de cambios en la distribución de conos .....	88
Ilustración 74 diagrama de gantt del proyecto.....	90
Ilustración 75 gráfica comparativa entre los mejores resultados de ambos gd .....	91
Ilustración 76 gráfica del porcentaje de mejora del gd nuevo vs gd anterior .....	92
Ilustración 77 corte del aro exterior. Si los extremos, L1 y L2, no tienen la misma dimensión (por exceso o defecto de material), las pistas no están centradas ( $L1 \neq L2$ ).....	96
Ilustración 78 muela de la rectificadora LIDKÖPING 35.....	98
Ilustración 79 rectificado de las caras del cono en DISKUS. F1: fuerza ejercida en la cara inferior; FS: fuerza ejercida en la cara superior; P: peso del cono.....	100
Ilustración 80 superficies a rectificar en NOVA 30 y Rectificado simultáneo de las 3 superficies del cono A.....	101
Ilustración 81 Ejes de NOVA 30. Los conos se mueven en el eje X y la muela en el eje Z. Nótese que la dimensión marcada no es la $Ti_{inv}$ sino aquella que tiene repercusión sobre la $Ti_{inv}$ .....	104
Ilustración 82 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	110
Ilustración 83 gráfica shapley intervencional.....	111
Ilustración 84 gráfica shapley condicional .....	111
Ilustración 85 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	112
Ilustración 86 gráfica shapley intervencional.....	113
Ilustración 87 gráfica shapley condicional .....	113
Ilustración 88 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	114
Ilustración 89 gráfica shapley intervencional.....	115
Ilustración 90 gráfica shapley condicional .....	115
Ilustración 91 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	116
Ilustración 92 gráfica shapley intervencional.....	117
Ilustración 93 gráfica shapley condicional .....	117
Ilustración 94 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	118
Ilustración 95 gráfica shapley intervencional.....	119
Ilustración 96 gráfica shapley condicional .....	119
Ilustración 97 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	120
Ilustración 98 gráfica shapley intervencional.....	121
Ilustración 99 gráfica shapley condicional .....	121
Ilustración 100 gráfica comparativa de la respuesta real obtenida frente a las predicciones .....	122
Ilustración 101 gráfica shapley intervencional.....	123
Ilustración 102 gráfica shapley condicional .....	123
Ilustración 103 gráfica del comportamiento de la posición fin de trabajo Z.....	124
Ilustración 104 gráfica del comportamiento de la posición fin de trabajo X.....	124
Ilustración 105 gráfica del comportamiento de la suma de correcciones eje X.....	125
Ilustración 106 gráfica del comportamiento de la suma de correcciones eje Z .....	125
Ilustración 107 gráfica del comportamiento del diámetro actual de muela.....	126
Ilustración 108 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	127

Ilustración 109 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	128
Ilustración 110 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	129
Ilustración 111 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	130
Ilustración 112 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	131
Ilustración 113 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	132
Ilustración 114 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	133
Ilustración 115 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	135
Ilustración 116 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	136
Ilustración 117 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	137
Ilustración 118 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	138
Ilustración 119 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	139
Ilustración 120 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	140
Ilustración 121 gráfica comparativa de las predicciones y de los resultados reales en los conos .....	141
Ilustración 122 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	143
Ilustración 123 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	144
Ilustración 124 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	145
Ilustración 125 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	146
Ilustración 126 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	148
Ilustración 127 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	149
Ilustración 128 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	150
Ilustración 129 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	151
Ilustración 130 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	152
Ilustración 131 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	153
Ilustración 132 gráfica comparativa de las predicciones y de los resultados reales en los aros .....	154
Ilustración 133 información general para el gemelo digital .....	155
Ilustración 134 resumen de distribución de aros en la simulación .....	155
Ilustración 135 distribución de conos con su familia y variables de control .....	156

Ilustración 136 resultado de la simulación.....	156
Ilustración 137 información general para el gemelo digital.....	157
Ilustración 138 resumen de distribución de aros en la simulación.....	157
Ilustración 139 distribución de conos con su familia y variables de control .....	158
Ilustración 140 resultado de la simulación.....	158
Ilustración 141 información general para el gemelo digital.....	159
Ilustración 142 resumen de distribución de aros en la simulación.....	159
Ilustración 143 distribución de conos con su familia y variables de control .....	160
Ilustración 144 resultado de la simulación.....	160
Ilustración 145 información general para el gemelo digital.....	161
Ilustración 146 resumen de distribución de aros en la simulación.....	161
Ilustración 147 distribución de conos con su familia y variables de control .....	162
Ilustración 148 resultado de la simulación.....	162
Ilustración 149 información general para el gemelo digital.....	163
Ilustración 150 resumen de distribución de aros en la simulación.....	163
Ilustración 151 distribución de conos con su familia y variables de control .....	164
Ilustración 152 resultado de la simulación.....	164
Ilustración 153 información general para el gemelo digital.....	165
Ilustración 154 resumen de distribución de aros en la simulación.....	165
Ilustración 155 distribución de conos con su familia y variables de control .....	166
Ilustración 156 resultado de la simulación.....	166
Ilustración 157 información general para el gemelo digital.....	167
Ilustración 158 resumen de distribución de aros en la simulación.....	167
Ilustración 159 distribución de conos con su familia y variables de control .....	168
Ilustración 160 resultado de la simulación.....	168
Ilustración 161 información general para el gemelo digital.....	169
Ilustración 162 resumen de distribución de aros en la simulación.....	169
Ilustración 163 distribución de conos con su familia y variables de control .....	170
Ilustración 164 resultado de la simulación.....	170
Ilustración 165 información general para el gemelo digital.....	171
Ilustración 166 resumen de distribución de aros en la simulación.....	171
Ilustración 167 distribución de conos con su familia y variables de control .....	172
Ilustración 168 resultado de la simulación.....	172
Ilustración 169 información general para el gemelo digital.....	173
Ilustración 170 resumen de distribución de aros en la simulación.....	173
Ilustración 171 distribución de conos con su familia y variables de control .....	174
Ilustración 172 resultado de la simulación.....	174
Ilustración 173 resumen de distribución de aros en la simulación.....	175
Ilustración 174 distribución de conos con su familia y variables de control .....	175
Ilustración 175 resultado de la simulación.....	176
Ilustración 176 resumen de distribución de aros en la simulación.....	176
Ilustración 177 distribución de conos con su familia y variables de control .....	177
Ilustración 178 resultado de la simulación.....	177
Ilustración 179 resumen de distribución de aros en la simulación.....	178
Ilustración 180 distribución de conos con su familia y variables de control .....	178
Ilustración 181 resultado de la simulación.....	179
Ilustración 182 resumen de distribución de aros en la simulación.....	179
Ilustración 183 distribución de conos con su familia y variables de control .....	180
Ilustración 184 resultado de la simulación.....	180
Ilustración 185 resumen de distribución de aros en la simulación.....	181
Ilustración 186 distribución de conos con su familia y variables de control .....	181

Ilustración 187 resultado de la simulación.....	182
Ilustración 188 resumen de distribución de aros en la simulación .....	182
Ilustración 189 distribución de conos con su familia y variables de control .....	183
Ilustración 190 resultado de la simulación.....	183
Ilustración 191 resumen de distribución de aros en la simulación .....	184
Ilustración 192 distribución de conos con su familia y variables de control .....	184
Ilustración 193 resultado de la simulación.....	185
Ilustración 194 resumen de distribución de aros en la simulación .....	185
Ilustración 195 distribución de conos con su familia y variables de control .....	186
Ilustración 196 resultado de la simulación.....	186
Ilustración 197 resumen de distribución de aros en la simulación .....	187
Ilustración 198 distribución de conos con su familia y variables de control .....	187
Ilustración 199 resultado de la simulación.....	188
Ilustración 200 resumen de distribución de aros en la simulación .....	188
Ilustración 201 distribución de conos con su familia y variables de control .....	189
Ilustración 202 resultado de la simulación.....	189
Ilustración 203 resumen de distribución de aros en la simulación .....	190
Ilustración 204 distribución de conos con su familia y variables de control .....	190
Ilustración 205 resultado de la simulación.....	191
Ilustración 206 información general para el gemelo digital.....	191
Ilustración 207 resumen de distribución de aros en la simulación.....	192
Ilustración 208 distribución de conos con su familia y variables de control .....	192
Ilustración 209 Resultado de la simulación .....	193
Ilustración 210 resumen de distribución de aros en la simulación .....	193
Ilustración 211 distribución de conos con su familia y variables de control .....	194
Ilustración 212 resultado de la simulación.....	194
Ilustración 213 resumen de distribución de aros en la simulación .....	195
Ilustración 214 distribución de conos con su familia y variables de control .....	195
Ilustración 215 resultado de la simulación.....	196
Ilustración 216 información general para el gemelo digital.....	196
Ilustración 217 distribución de conos con su familia y variables de control .....	197
Ilustración 218 resultado de la simulación.....	197
Ilustración 219 resumen de distribución de aros en la simulación .....	198
Ilustración 220 distribución de conos con su familia y variables de control .....	198
Ilustración 221 resultado de la simulación.....	199
Ilustración 222 resumen de distribución de aros en la simulación .....	199
Ilustración 223 distribución de conos con su familia y variables de control .....	200
Ilustración 224 resultado de la simulación.....	200
Ilustración 225 resumen de distribución de aros en la simulación .....	201
Ilustración 226 distribución de conos con su familia y variables de control .....	201
Ilustración 227 Resultado de la simulación .....	202

## INDICE DE TABLAS

Tabla 1 comparación de modelos gaussianos .....	30
Tabla 2 comparación de modelos svm.....	33
Tabla 3 general de los resultados de los entrenamientos y de los test con sus respectivos indicadores .....	39
Tabla 4 variables y factores influyentes para los modelos de aros.....	52
Tabla 5 variables y factores influyentes para los modelos de conos .....	53
Tabla 6 representación de las estrategias de emparejamiento utilizadas para modelar la estación de ensamblaje. .....	60
Tabla 7 modelos para el entrenamiento con datos sintéticos .....	62
Tabla 8 resumen de resultados obtenidos entrenando con datos sintéticos.....	65
Tabla 9 modelos de entrenamiento de los conos .....	69
Tabla 10 modelos de entrenamiento y test de aros.....	75
Tabla 11 costes para el desarrollo del gemelo digital.....	89
Tabla 12 modelos de entrenamiento y test de datos sintéticos .....	110
Tabla 13 modelos de entrenamiento y test de datos sintéticos .....	112
Tabla 14 modelos de entrenamiento y test de datos sintéticos .....	114
Tabla 15 modelos de entrenamiento y test de datos sintéticos .....	116
Tabla 16 modelos de entrenamiento y test de datos sintéticos .....	118
Tabla 17 modelos de entrenamiento y test de datos sintéticos .....	120
Tabla 18 modelos de entrenamiento y test de datos sintéticos .....	122
Tabla 19 modelos de entrenamiento de los conos .....	126
Tabla 20 modelos de entrenamiento de los conos .....	127
Tabla 21 modelos de entrenamiento de los conos .....	129
Tabla 22 modelos de entrenamiento de los conos .....	130
Tabla 23 modelos de entrenamiento de los conos .....	131
Tabla 24 modelos de entrenamiento de los conos .....	132
Tabla 25 modelos de entrenamiento de los conos .....	133
Tabla 26 modelos de entrenamiento de los conos .....	134
Tabla 27 modelos de entrenamiento de los conos .....	135
Tabla 28 modelos de entrenamiento de los conos .....	136
Tabla 29 modelos de entrenamiento de los conos .....	137
Tabla 30 modelos de entrenamiento de los conos .....	138
Tabla 31 modelos de entrenamiento de los conos .....	139
Tabla 32 modelos de entrenamiento de los conos .....	140
Tabla 33 modelos de entrenamiento de los aros.....	142
Tabla 34 modelos de entrenamiento de los conos .....	143
Tabla 35 modelos de entrenamiento de los aros.....	145
Tabla 36 modelos de entrenamiento de los aros.....	146
Tabla 37 modelos de entrenamiento de los aros.....	147
Tabla 38 modelos de entrenamiento de los aros.....	148
Tabla 39 modelos de entrenamiento de los aros.....	149
Tabla 40 modelos de entrenamiento de los aros.....	150
Tabla 41 modelos de entrenamiento de los aros.....	151
Tabla 42 modelos de entrenamiento de los aros.....	152
Tabla 43 modelos de entrenamiento de los aros.....	153

# 1. INTRODUCCIÓN

El presente Trabajo de Fin de Grado “Desarrollo de un gemelo digital de un proceso multietapa de rodamientos” ha sido elaborado en el Departamento de Ingeniería de Diseño y Fabricación y métodos estadísticos de la Escuela de Ingeniería y Arquitectura de la Universidad de Zaragoza.

## 1.1 OBJETIVO

El presente TFG se desarrolla respecto a un proyecto previo desarrollado en una línea de producción multietapa de rodamientos de rodillos cónicos de doble hilera para camiones. Este proyecto incluyó la puesta en marcha de sensores y sistemas de trazabilidad mediante códigos de identificación datamatrix para el control detallado de la línea de producción. Además, incluyó la creación de un gemelo digital basado en datos reales de producción, permitiendo la asociación precisa entre los aros y los conos en la zona de ensamblaje, teniendo en cuenta las tolerancias de dichas piezas. Este método mejoró la eficiencia de ensamblaje eliminando tiempos de espera, mejorando el control del proceso y reduciendo los costes de inventario y espacio en la zona de emparejado.

El objetivo de este TFG se enfoca en extender y optimizar el proyecto previamente mencionado mediante el uso de técnicas avanzadas de machine learning y con la integración de modelos analíticos con el gemelo digital existente. En primer lugar, se trabajó con datos sintéticos, lo que permitió crear modelos de machine learning enfocados en los procesos de rectificado de aros y conos. Durante esta etapa, se analizaron los factores de entrada que influyen en las variables de salida, se estudiaron las relaciones entre variables y se evaluó el impacto del ruido y la incertidumbre en la precisión de las predicciones. Los resultados iniciales fueron validados con datos sintéticos para facilitar su extrapolación a datos reales, utilizando la Toolbox de machine learning de MATLAB como herramienta principal de desarrollo.

Posteriormente, se realizó un entrenamiento con datos reales obtenidos directamente de la línea de producción. Esto incluyó la integración de nuevos datos en tres áreas principales: la línea de aros, donde se identificaron variables clave e implementaron modelos ajustados; la línea de conos, con un análisis detallado y la optimización de las predicciones; y la zona de emparejado, donde se desarrollaron modelos específicos para una integración efectiva en el gemelo digital. Los modelos entrenados fueron evaluados y comparados para determinar su ajuste y capacidad predictiva en cada etapa del proceso.

Finalmente, el gemelo digital fue optimizado mediante la modificación de sus parámetros clave, con el objetivo de evaluar el impacto del número de variables, los métodos de emparejamiento y los tiempos de entrenamiento en la eficiencia del sistema. Además, se identificaron configuraciones que maximizan los emparejamientos exitosos, y los resultados obtenidos de los modelos de machine learning se integraron en el gemelo digital, mejorando su precisión y robustez. También se realizó un gemelo digital modificado y adaptado a los datos de la línea proporcionados.

En resumen, este TFG ha logrado desarrollar, validar y optimizar modelos de machine learning para aumentar la precisión, eficiencia y control de una línea de producción.

multietapa de rodamientos de rodillos cónicos de doble hilera, integrando dichos modelos en un gemelo digital adaptado a los nuevos datos de producción real.

## 1.2 ESTRUCTURA

Las actividades realizadas para la elaboración de este gemelo digital son las siguientes:

En primer lugar, se trabaja con la toolbox de Matlab con un modelo de datos sintéticos de temperaturas para ver la influencia del ruido, de la incertidumbre, de las variables, de la correlación entre ellas, los modelos que más precisión tienen con los entrenamientos y testeos, como primera aproximación a las herramientas de machine learning. Los resultados obtenidos dan una idea de cómo proceder para el proceso de fabricación objeto de estudio.

En segundo lugar, se trabaja con la línea de los conos en la que se procede de forma similar a la línea de los aros. En esta parte del proceso hay dos tipos de conos: conos A y conos B. Se ha procedido a hacer diferentes pruebas entrenando los conos A y testeando los B y viceversa, o directamente entrenando datos del A y testeando con datos posteriores del mismo cono.

En tercer lugar, se trabaja con la línea de los aros en la que se analizan los mejores modelos para entrenar y testear los datos, cada cuanto es mejor hacer los entrenamientos para que la precisión de las predicciones sea adecuada así como las variables que más peso tienen en dichas predicciones. Se entrena el modelo con unos datos y posteriormente se testea con otros diferentes para ver con qué precisión se predicen los resultados.

Finalmente, se trabaja con el gemelo digital que engloba las tres áreas: aros, conos y emparejamiento. En esta parte se modifican parámetros de cada parte de la línea y se analiza el cómo afectan estos cambios al resultado final que es el emparejamiento de las piezas mencionadas anteriormente (años y conos). Cabe destacar que se van a hacer pruebas por un lado, con el gemelo digital (GD) con los datos y procedimientos que se hacían hasta ahora y con el GD con datos actualizados y con un cambio de estrategia en los modelos de entrenamiento para mejorar este gemelo digital.

## 1.3 CONTENIDO DE LA MEMORIA

La memoria de este proyecto se organiza de la siguiente manera:

- Capítulo 2, se introduce los métodos previos al gemelo digital en la línea de producción de rodamientos así como la implementación del mismo y el futuro del GD.
- Capítulo 3, se expone todo lo relacionado con el machine learning y las herramientas empleadas en la realización del GD óptimo.
- Capítulo 4, desarrolla toda la línea de fabricación de los rodamientos con toda su domótica y métodos y variables que se tienen en cuenta.
- Capítulo 5, contiene todas las pruebas de entrenamiento y testeо de los modelos de machine learning (conos y aros) además de la etapa final de las pruebas con el GD.
- Capítulo 6, estimación económica
- Capítulo 7, conclusión del conjunto de resultados obtenidos a lo largo de las simulaciones.
- Capítulo 8, bibliografía empleada.

En los anexos se incluye la siguiente información adicional:

- Anexo 1, procesos de fabricación de aros y conos (datos restantes)
- Anexo 2, resto de pruebas con datos sintéticos (gráficas)
- Anexo 3, resto de pruebas con los conos (gráficas)
- Anexo 4, resto de pruebas con los aros (gráficas)
- Anexo 5, gemelo digital anterior y gemelo digital nuevo
- Anexo 6, scripts empleados

## 2. ESTADO DEL ARTE

En este capítulo se va a analizar el estado del arte relacionado con el proceso de fabricación de rodamientos mediante un gemelo digital. Se presentan las técnicas tradicionales y los beneficios obtenidos.

### 2.1 REVISIÓN DE INVESTIGACIONES ANTERIORES

#### 2.1.1 FABRICACIÓN DE LOS COMPONENTES (AROS Y CONOS)

##### 2.1.1.1 DISEÑO Y PLANIFICACIÓN

El diseño de los aros y conos se basaba en modelos CAD tradicionales, pero no había una sincronización directa con simulaciones del proceso de fabricación o análisis en tiempo real. La planificación de la producción se realizaba manualmente o con sistemas básicos de gestión (ERP) que no podían prever problemas dinámicamente.

##### 2.1.1.2 MECANIZADO Y TRATAMIENTO TÉRMICO

Los aros y conos se fabricaban mediante procesos de mecanizado en tornos y fresadoras convencionales. Los tratamientos térmicos para endurecer el material se controlaban con parámetros predefinidos, basándose en experiencia previa, sin herramientas avanzadas para ajustar parámetros en función de datos en tiempo real.

##### 2.1.1.3 CONTROL DE CALIDAD

El control se realizaba mediante inspecciones periódicas con herramientas manuales, como micrómetros y calibradores, o sistemas de inspección por coordenadas (CMM) independientes de la línea. Esto implicaba pausas en la producción y tiempos muertos para ajustes.

##### 2.1.1.4 ALMACENAMIENTO Y LOGÍSTICA

Los componentes (aros y conos) terminados se almacenaban en áreas de inventario. La gestión del inventario era manual o semiautomatizada, sin sistemas avanzados de trazabilidad en tiempo real. Los errores en la planificación o en la logística podían generar cuellos de botella o excesos de stock, afectando la eficiencia del ensamblaje. Uno de los problemas que también aparecían era que las áreas de almacenamiento eran muy grandes, aumentando los costes de inventario.

### 2.1.1.5 ENSAMBLAJE DE RODAMIENTOS

El ensamblaje de los rodamientos (emparejamiento de aros y conos con los elementos rodantes) dependía de procesos semiautomatizados o manuales. Los ajustes se realizaban basándose en tolerancias predefinidas y en pruebas de ajuste estáticas. Si un lote de componentes no cumplía con las especificaciones, se descartaba o reelaboraba, aumentando los costos. No existía un control integrado que permitiera analizar las condiciones dinámicas del ensamblaje ni predecir problemas futuros en el rendimiento del rodamiento.

### 2.1.1.6 MANTENIMIENTO Y MEJORAS

El mantenimiento de las máquinas seguía un enfoque reactivo o preventivo. Las máquinas se reparaban cuando fallaban o se inspeccionaban en intervalos regulares, sin datos en tiempo real para anticipar fallas. Las mejoras del proceso se realizaban mediante prueba y error, basándose en la experiencia del personal y en el análisis de los problemas.

### 2.1.1.7 LIMITACIONES DE ESTE ENFOQUE

- Falta de integración de datos: cada fase del proceso operaba de forma independiente, sin una relación directa entre el diseño, la producción y el montaje.
- Mayor tiempo y costo: la identificación tardía de defectos y la ausencia de simulaciones provocaban un derroche de tiempo y materiales.
- Menor flexibilidad: modificar los parámetros o ajustar el procedimiento a nuevas especificaciones resultaba más lento y susceptible a fallos.
- Incapacidad para predecir problemas: sin la realización de simulaciones o análisis predictivos, se operaba de forma reactiva, lo que restringía la mejora del proceso.

## 2.2 EVOLUCIÓN DE LOS GEMELOS DIGITALES

Con los gemelos digitales, se logra una integración completa y dinámica entre diseño, producción y ensamblaje. Las simulaciones permiten detectar y prever problemas, optimizar parámetros y ajustar procesos en tiempo real, mejorando la calidad, reduciendo costes, simplificando tareas y acelerando los tiempos de producción [\[9\]](#). Esto ha revolucionado la industria de los rodamientos y otras líneas de fabricación complejas.

## 2.2.1 CONTEXTO

- El Gemelo digital online que es el que interactúa con la línea en tiempo real para mejorar la eficiencia todo lo posible y el gemelo offline es el que usa datos actuales para simular sin afectar a la línea [7].
- Lo que mide el cliente es la holgura axial: el juego de los conos dentro del aro. Lo que más influye en la holgura axial (HA) son las variables de los aros y de los conos,  $T_e$  ( distancia entre pistas de rodadura ) y  $T_{int}$  ( distancia entre las superficies del cono y del aro ) respectivamente. La emparejadora quiere sacar la mejor HA posible [5,6]; [1,2].
- La producción de aros es más rápida y ágil que la de los conos. Los conos guían la producción del aro ya que en función del cono que llega se fabrica el aro. El rectificado de conos es el proceso más lento de la línea. Mientras se fabrica el cono, mediante los datos recogidos se le indica a la rectificadora de aros de que familia tiene que ser el aro para ajustarse lo mejor posible a dicho cono.
- Los rodillos que constituyen también otra parte del rodamiento y se montan en los conos antes del emparejado.
- El emparejamiento es directo si nada más llegar se puede emparejar los conos y los aros sin almacenar e indirecto si se almacenan para ser emparejados posteriormente.
- Cada pieza tiene un código QR que se marca con láser durante la producción que se traduce en un datamatrix ( identificación de la pieza ) de 20 dígitos para que quede registrada la pieza y sea identificada en la emparejadora.
- Existen 20 familias de conos y de aros cada una dentro de un rango de tolerancias (se verá más adelante). El emparejado en L empareja dos elementos de la familia 15 por ejemplo y luego el otro elemento dos familias por encima o dos por debajo. El emparejamiento en V es una pieza de la familia 8 y las otras dos piezas dos familias por encima o dos por debajo de 8. El emparejado recto solo permite emparejar piezas que pertenezcan a la misma familia.
- Con respecto a los parámetros usados en el gemelo digital, si te pasas del número de parámetros hay problemas de sobreajuste y al revés falta de precisión. Los parámetros relevantes se sacan de manera experimental y por experiencia de la empresa. Después de desarrollar el gemelo digital offline con Matlab, para hilar fino el gemelo digital online se elabora con Python para desarrollarlo de manera estable.
- Hay dispersiones en las máquinas, la producción de conos es cíclica para llenar todo el espectro de familias y asegurar estadísticamente con menos error que se le asocie un aro. Hay dispersión inherente en las máquinas de rectificado de aros y conos es decir que lo que se obtiene realmente se aproxima a lo que se prevé pero no de manera exacta.

- De todos los datos que se almacenan en la base de datos Mongo DB cloud, esta base de datos solo envía los datos relevantes al gemelo digital que van a producir efectos en la producción. El gemelo online predice la familia a la que va a pertenecer el cono que se está rectificando. Sabe la distribución de conos en la emparejadora y predice la distribución futura de conos, calcula la familia óptima de aros después. Todo esto pasa cuando llega un cono a la rectificadora. El gemelo digital saca tanto las variables de control actuales que se necesitan en el momento como las variables de control futuras. En el módulo de gemelo digital se ve si el modelo está funcionando bien o no, si sí entonces se procede como hasta ahora y si no se comunica que se encargara el operario de realizarlo temporalmente [10,11].
- En el modelo de emparejado se sacan datos de cómo han ido los emparejamientos y la HA. Antes de implantar el GD, si por ejemplo se arranca la línea desde 0, no se podría hacer un aro hasta pasada hora y media que se tardaría en saber la familia del cono pero con el GD no porque se hacen predicciones. Además de tener en cuenta que los aros tardan media hora, las distribuciones de conos pueden cambiar e igual por eso ese aro no se puede emparejar directamente. Se implementa en las empresas para reducir tiempos y costes, sin embargo lleva un par de años implantarlo en la línea de producción. En las empresas aún no hay muchas de estas tecnologías todavía pero cada vez más [8].
- Carencias: residuos demasiado altos, falta de más datos y grado de autonomía de mejora limitado.

## 2.2.2 FUTURO DE LOS GEMELOS DIGITALES: GD ACTUAL VS GD FUTURO

Las principales diferencias entre un gemelo digital actual y un gemelo digital autosuficiente radican en el grado de autonomía, la capacidad de aprendizaje y la interacción con el sistema físico.

Un gemelo digital actual es una herramienta de apoyo que depende de la intervención humana para interpretar datos, ajustar modelos y tomar decisiones basadas en sus simulaciones. Por otro lado, un gemelo digital autosuficiente actúa de manera autónoma, ajusta parámetros en tiempo real, aprende continuamente mediante machine learning y ejecuta acciones directamente sobre el sistema físico. Mientras que el gemelo digital actual se limita al monitoreo y la simulación, el autosuficiente puede cerrar el ciclo de retroalimentación, optimizando sistemas dinámicos y colaborando con otros gemelos en ecosistemas más amplios, como fábricas conectadas o ciudades inteligentes.

## 3.CONCEPTOS DE MACHINE LEARNING

### 3.1 DEFINICIÓN

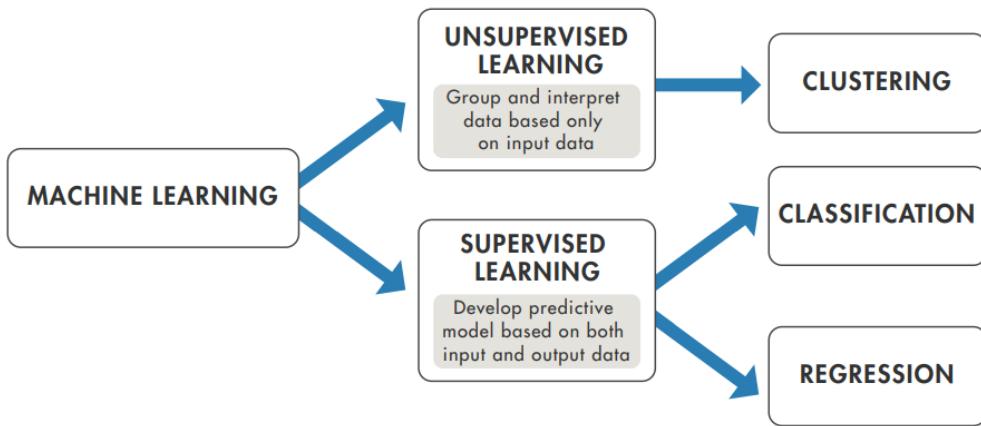
El machine learning ( aprendizaje automático ) es un campo de la Inteligencia Artificial (IA) que se fundamenta en la creación de algoritmos y métodos que habilitan a las computadoras para adquirir datos y realizar pronósticos o tomar decisiones sin estar programadas para cada actividad de forma constante. Este último instruye a las computadoras a realizar lo que es natural para los seres humanos y animales: aprender de la experiencia. Los algoritmos de aprendizaje automático emplean técnicas informáticas para adquirir información directamente de los datos, sin tener que confiar en un modelo preestablecido. Los algoritmos optimizan su desempeño de manera adaptativa conforme se incrementa hasta cierto punto la cantidad y la calidad de muestras disponibles para el aprendizaje.

Los algoritmos de machine learning encuentran patrones naturales en los datos que generan información, ayudan a tomar mejores decisiones y a hacer predicciones. Se utilizan todos los días para tomar decisiones críticas en diagnósticos médicos, comercio de acciones, pronósticos de carga energética además de usarse en muchos otros campos. Los sitios de medios confían en el aprendizaje automático para filtrar millones de opciones y ofrecer recomendaciones de canciones o películas. Los minoristas lo utilizan para obtener información sobre el comportamiento de compra de sus clientes.

Con el auge del big data, el machine learning se ha vuelto particularmente importante para resolver problemas en áreas como estas:

- Finanzas computacionales, para la puntuación de crédito y el comercio algorítmico.
- Procesamiento de imágenes y visión por computadora, para el reconocimiento facial, la detección de movimiento y la detección de objetos.
- Biología computacional, para la detección de tumores, el descubrimiento de medicamentos y la secuenciación de ADN.
- Producción de energía, para la previsión de precios y carga.
- Automotriz, aeroespacial y manufactura, para el mantenimiento predictivo.
- Procesamiento de lenguaje natural.

El machine learning utiliza dos tipos de técnicas: el aprendizaje supervisado, que entrena un modelo con datos de entrada y de salida conocidos para que pueda predecir salidas futuras, y el aprendizaje no supervisado, que encuentra patrones ocultos o estructuras intrínsecas en los datos de entrada.



#### **ILUSTRACIÓN 1 MÉTODOS DE APRENDIZAJE PARA ENTRENAR LA COMPUTADORA**

**Fuente:** <https://es.mathworks.com/discovery/linear-regression.html>

El objetivo del machine learning con aprendizaje supervisado es construir un modelo que haga predicciones basadas en evidencia en presencia de incertidumbre. Un algoritmo de aprendizaje supervisado toma un conjunto conocido de datos de entrada y respuestas conocidas a esos datos (salida) y entrena un modelo para generar predicciones razonables para la respuesta a nuevos datos. El aprendizaje supervisado utiliza técnicas de clasificación y regresión para desarrollar modelos predictivos.

- Las técnicas de clasificación predicen respuestas discretas, por ejemplo, si un correo electrónico es genuino o spam, o si un tumor es canceroso o benigno. Los modelos de clasificación clasifican los datos de entrada en categorías. Las aplicaciones típicas incluyen imágenes médicas, reconocimiento de voz y puntuación crediticia.
- Las técnicas de regresión predicen respuestas continuas, por ejemplo, cambios en la temperatura o fluctuaciones en la demanda de energía. Las aplicaciones típicas incluyen pronósticos de carga eléctrica y comercio algorítmico.

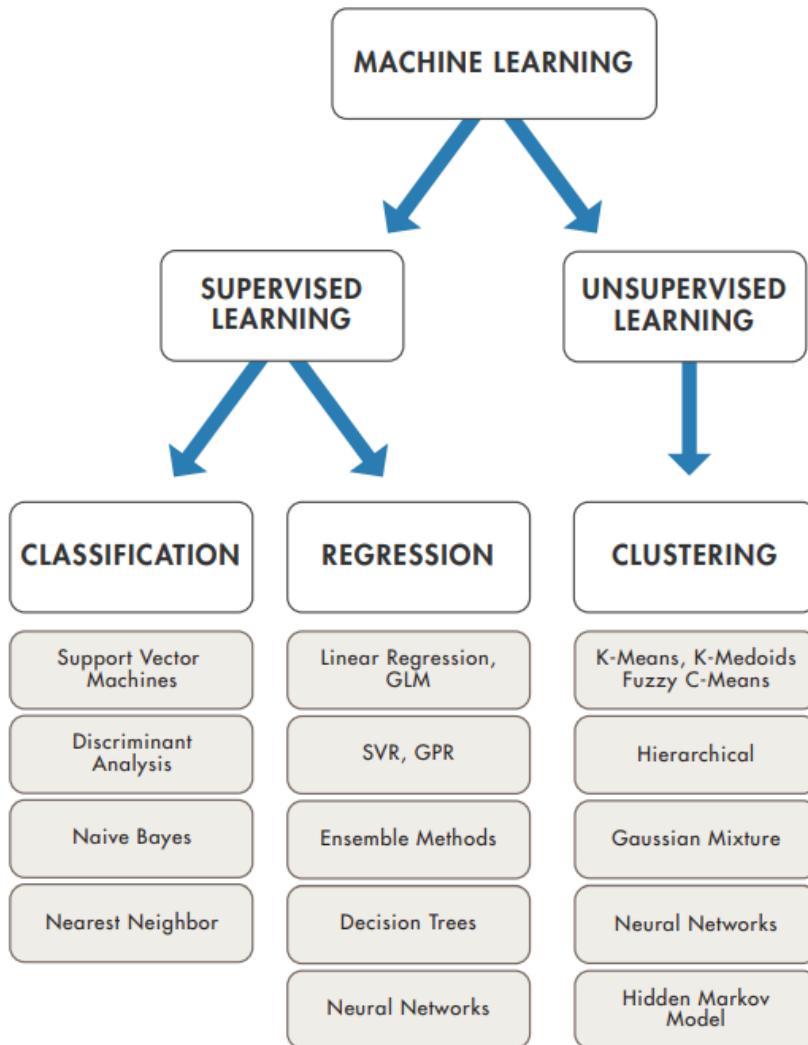
El proceso de aprendizaje no supervisado descubre patrones encubiertos o estructuras inherentes en la información. Se emplea para obtener deducciones de grupos de datos que se componen de datos de entrada sin respuestas etiquetadas.

El agrupamiento ( clustering ) es la técnica de aprendizaje no supervisado más común. Se utiliza para el análisis exploratorio de datos para encontrar patrones ocultos o agrupaciones en los datos. Las aplicaciones del agrupamiento incluyen el análisis de secuencias de genes, la investigación de mercado y el reconocimiento de objetos.

**ILUSTRACIÓN 2 MÉTODO DE CLUSTERING**

Fuente: <https://es.mathworks.com/discovery/linear-regression.html>

Hay decenas de algoritmos de aprendizaje automático supervisado y no supervisado, y cada uno adopta un enfoque diferente para aprender. No hay un método mejor o una solución única para todos. Encontrar el algoritmo correcto es en parte un proceso de prueba y error. Sin embargo, la selección del algoritmo también depende del tamaño y del tipo de los datos con los que se trabaje, de los conocimientos que se quieren obtener de los datos y de cómo se utilizarán esos conocimientos.

**ILUSTRACIÓN 3 DIFERENTES MÉTODOS DE ANÁLISIS DE DATOS MEDIANTE MACHINE LEARNING**

Fuente: <https://es.mathworks.com/discovery/linear-regression.html>

El uso de machine learning es pertinente cuando se tiene una tarea o problema complejo que involucre una gran cantidad de datos y muchas variables, pero no existe una fórmula o ecuación existente.

## 3.2 HERRAMIENTAS DE LA TOOLBOX DE MATLAB UTILIZADAS

### 3.2.1 ENTRENAMIENTO

#### 3.2.1.1 MODELOS

 2.13	SVM	RMSE (Validation): 0.014019
Last change:	Coarse Gaussian SVM	5/5 features
 2.14	Efficient Linear	RMSE (Validation): 0.020368
Last change:	Efficient Linear Least Squares	5/5 features
 2.15	Efficient Linear	RMSE (Validation): 0.020407
Last change:	Efficient Linear SVM	5/5 features
 2.16	Ensemble	RMSE (Validation): 0.013403
Last change:	Boosted Trees	5/5 features
 2.17	Ensemble	RMSE (Validation): 0.013456
Last change:	Bagged Trees	5/5 features
 2.18	Gaussian Process Regression	RMSE (Validation): 0.013730
Last change:	Squared Exponential GPR	5/5 features
 2.19	Gaussian Process Regression	RMSE (Validation): 0.013382
Last change:	Matern 5/2 GPR	5/5 features
 2.20	Gaussian Process Regression	RMSE (Validation): 0.013301
Last change:	Exponential GPR	5/5 features
 2.21	Gaussian Process Regression	RMSE (Validation): 0.013332
Last change:	Rational Quadratic GPR	5/5 features
 2.22	Neural Network	RMSE (Validation): 0.016462
Last change:	Narrow Neural Network	5/5 features
 2.23	Neural Network	RMSE (Validation): 0.014991
Last change:	Medium Neural Network	5/5 features
 2.24	Neural Network	RMSE (Validation): 0.022504
Last change:	Wide Neural Network	5/5 features
 2.25	Neural Network	RMSE (Validation): 0.014933
Last change:	Bilayered Neural Network	5/5 features
 2.26	Neural Network	RMSE (Validation): 0.014769
Last change:	Trilayered Neural Network	5/5 features
 2.27	Kernel	RMSE (Validation): 0.014483
Last change:	SVM Kernel	5/5 features

#### ILUSTRACIÓN 4 EJEMPLOS DE MODELOS EMPLEADOS EN EL ANÁLISIS PREDICTIVO POR MACHINE LEARNING EN MATLAB

##### 3.2.1.1.1 REGRESIÓN LINEAL

La regresión lineal es un modelo estadístico simple que se utiliza para predecir una variable dependiente continua basada en una o más variables independientes. Debido a que los modelos de regresión lineal son fáciles de interpretar y entrenar, a menudo son los primeros modelos que se prueban al trabajar con un nuevo conjunto de datos. Este modelo asume que la relación entre las variables es lineal, es decir, que se puede representar como una línea recta en un gráfico. La regresión lineal simple se utiliza cuando hay una sola variable independiente, mientras que la regresión lineal múltiple

trabaja con varias variables independientes. La ecuación del modelo se construye de manera que minimice el error entre las predicciones del modelo y los datos reales. Aunque es fácil de interpretar y entrenar, su principal limitación es que no puede capturar relaciones no lineales entre las variables, y es muy sensible a los valores atípicos.

Regresión lineal simple: modelos que utilizan un único predictor. La ecuación general es:

$$Y = \beta_0 + \beta_1 X + \epsilon$$

Regresión lineal múltiple: modelos que utilizan múltiples predictores. Esta regresión tiene múltiples  $X_i$  (variable predictora) para predecir la respuesta,  $Y$  (variable de respuesta). Este es un ejemplo de ecuación:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon$$

Donde:

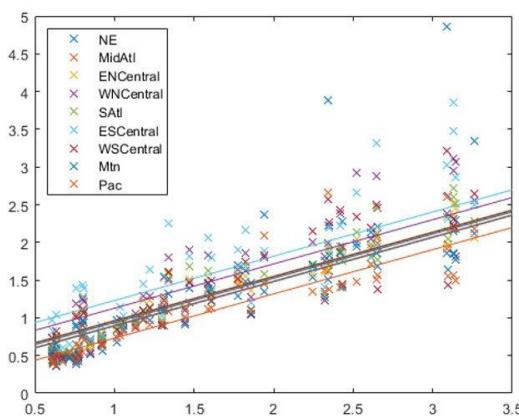
- $\beta_0$ : Intersección con el eje  $Y$ .
- $\beta_1$ : Pendiente de la línea.
- $\epsilon$ : Error residual.

Regresión lineal multivariante: modelos para varias variables de respuesta. Esta regresión tiene múltiples  $Y_i$  que derivan de los mismos datos  $Y$ . Se expresan con fórmulas diferentes. Este es un ejemplo del sistema con 2 ecuaciones:

$$Y_1 = \beta_{01} + \beta_{11} X_1 + \epsilon_1$$

$$Y_2 = \beta_{02} + \beta_{12} X_1 + \epsilon_2$$

$$\begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \begin{pmatrix} \beta_{01} & \beta_{11} \\ \beta_{02} & \beta_{12} \end{pmatrix} \begin{pmatrix} 1 \\ X_1 \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \end{pmatrix}$$

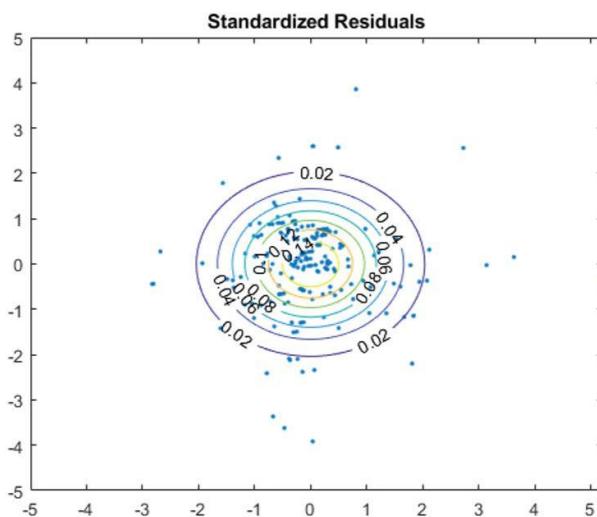


**ILUSTRACIÓN 5 EJEMPLO DE REGRESIÓN LINEAL MULTIVARIANTE QUE MUESTRA CÓMO PREDECIR LAS ESTIMACIONES DE GRIPE EN 9 REGIONES DE EE. UU. (VARIABLES DE RESPUESTA,  $Y_i$ ), BASADAS EN LA SEMANA DEL AÑO (VARIABLE PREDICTORA,  $X$ ).**

Fuente: <https://es.mathworks.com/discovery/linear-regression.html>

Regresión lineal múltiple multivariante: modelos que utilizan varios predictores para múltiples variables de respuesta. Esta regresión tiene múltiples  $X_i$  para predecir varias respuestas  $Y_i$ . Esta es una generalización de las ecuaciones:

$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1q} \\ 1 & x_{21} & x_{22} & \dots & x_{2q} \\ 1 & x_{31} & x_{32} & \dots & x_{3q} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nq} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \vdots \\ \beta_q \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \vdots \\ \epsilon_n \end{pmatrix}$$



**ILUSTRACIÓN 6 EJEMPLO DE REGRESIÓN LINEAL MÚLTIPLE MULTIVARIANTE QUE CALCULA LAS MPG EN CIUDAD Y AUTOPISTA (COMO VARIABLES DE RESPUESTA,  $Y_1$  Y  $Y_2$ ) A PARTIR DE TRES VARIABLES: DISTANCIA ENTRE EJES, PESO EN VACÍO Y TIPO DE COMBUSTIBLE (VARIABLES PREDICTORAS,  $X_1$ ,  $X_2$  Y  $X_3$ ).**

Fuente: <https://es.mathworks.com/discovery/linear-regression.html>

Aplicaciones de la regresión lineal:

La regresión lineal cuenta con ciertas características ideales para las siguientes aplicaciones:

- Predicción o pronóstico: para crear un modelo de pronóstico para un conjunto de datos específico. A partir de la moda, se puede usar la regresión lineal para predecir valores de respuesta donde solo se conocen los predictores.
- Para determinar si existe una relación entre una variable y un predictor ,y cuán estrecha es esta relación.

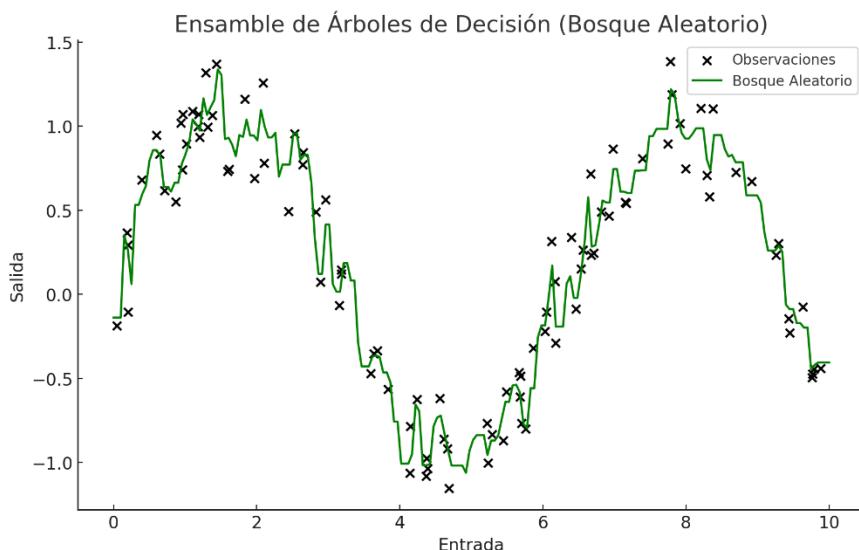
### 3.2.1.1.2 ÁRBOLES DE REGRESIÓN

Los árboles de regresión son modelos basados en dividir los datos en subconjuntos más pequeños según características específicas, representadas como nodos en un árbol. Cada nodo interno plantea una pregunta basada en las características de los datos, y cada hoja del árbol representa un valor de predicción. A diferencia de la regresión lineal, los árboles de regresión pueden capturar relaciones no lineales y manejar tanto variables continuas como categóricas. Sin embargo, pueden ser propensos al sobreajuste, especialmente si el árbol es demasiado profundo. Este problema puede mitigarse con métodos de poda o mediante el uso de técnicas como el ensamble de árboles (bagging o boosting), que combinan múltiples árboles para mejorar la precisión del modelo.

#### Ensamble:

En los métodos de ensamble, varios árboles de decisión más débiles se combinan para formar un ensamble más fuerte. Un árbol de decisión bagged (o en bolsa) consiste en árboles que se entran de manera independiente utilizando muestras (bootstrap) del conjunto de datos de entrada.

El boosting implica agregar iterativamente y ajustar el peso de los aprendices débiles. Este enfoque pone un énfasis particular en las observaciones mal clasificadas o en ajustar nuevos aprendices para minimizar el error cuadrático medio entre la respuesta observada y la predicción agregada de todos los aprendices previamente generados.

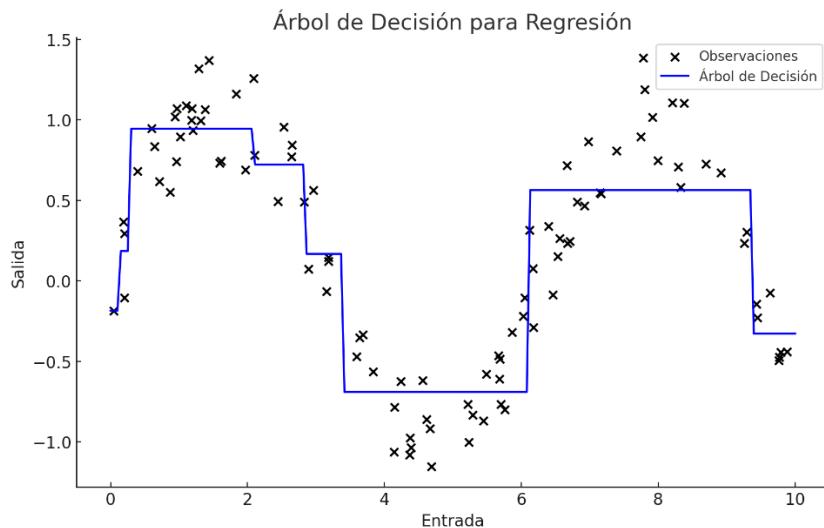


**ILUSTRACIÓN 7 GRÁFICA TÍPICA DE ÁRBOLES DE ENSAMBLE**

#### Decisión:

Un árbol de decisión permite predecir respuestas a los datos siguiendo las decisiones del árbol desde la raíz (inicio) hasta un nodo hoja. Un árbol está compuesto por condiciones de ramificación en las que el valor de un predictor se compara con un peso

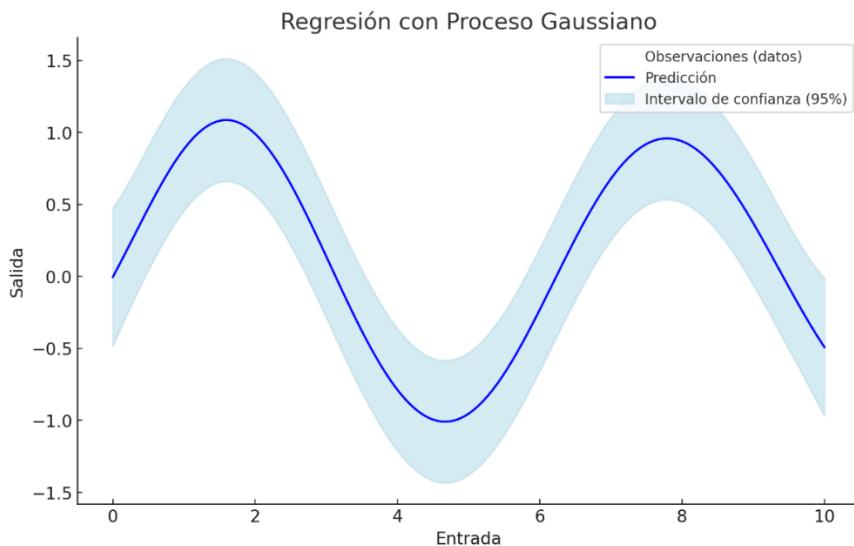
entrenado. El número de ramas y los valores de los pesos se determinan durante el proceso de entrenamiento. Además, se puede realizar una modificación adicional, conocida como poda, para simplificar el modelo.



**ILUSTRACIÓN 8 GRÁFICA TÍPICA DE ÁRBOLES DE DECISIÓN**

### 3.2.1.1.3 GAUSSIANOS

Los procesos gaussianos para regresión (GPR) son modelos no paramétricos que suponen que los datos pueden describirse mediante una distribución gaussiana multivariante. En lugar de predecir un valor único, el GPR estima una distribución probabilística para cada predicción, lo que proporciona no solo una predicción central, sino también una medida de la incertidumbre. Esto los hace especialmente útiles en situaciones donde la confianza en las predicciones es tan importante como las propias predicciones. Los procesos gaussianos dependen de funciones de kernel que determinan la relación entre los puntos de datos. Aunque son muy flexibles y precisos, tienen el inconveniente de que su coste computacional crece exponencialmente con el tamaño del conjunto de datos, lo que los hace inadecuados para problemas con grandes volúmenes de datos.



**ILUSTRACIÓN 9 GRÁFICA TÍPICA DE PROCESOS GAUSSIANOS**

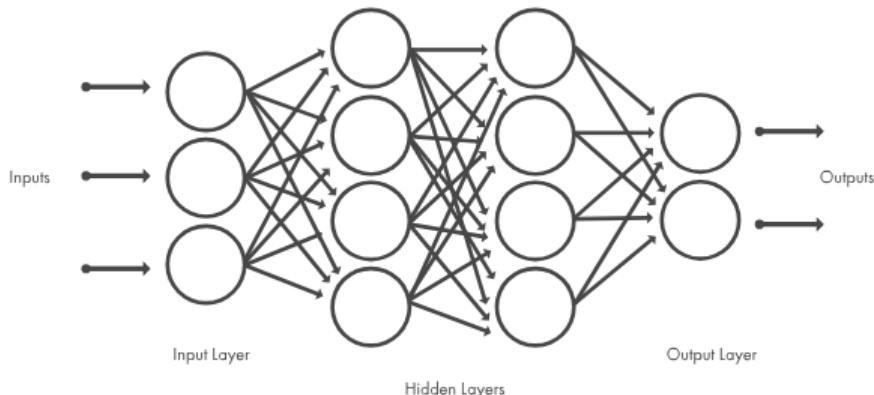
Estos modelos son ampliamente utilizados en análisis espacial para realizar interpolaciones en presencia de incertidumbre. Existen varios tipos de modelos gaussianos:

Modelo/característica	Exponencial Cuadrado (RBF)	Racional Cuadrático (RQ)	Matern 5/2
Suavidad	Muy suave, sin discontinuidades	Ajustable, puede ser más rugoso	Moderadamente suave, permite cierta rugosidad
Adaptabilidad a escalas	No tan flexible para escalas múltiples	Muy flexible a varias escalas de longitud	Moderadamente flexible, adecuado para datos con algunas irregularidades
Propósito	Ideal para funciones suaves y continuas	Bueno para modelar datos con variabilidad a diferentes escalas	Bueno para datos con variabilidad, pero con algo de picos
Usos comunes	Datos continuos y suaves	Datos con variabilidad en múltiples escalas	Datos con irregularidades moderadas

**TABLA 1 COMPARACIÓN DE MODELOS GAUSSIANOS**

### 3.2.1.1.4 REDES NEURONALES

Inspiradas en el cerebro humano, las redes neuronales consisten en nodos o neuronas interconectadas en una estructura en capas que relacionan las entradas con las salidas deseadas. El modelo de machine learning se entrena modificando iterativamente las fuerzas de las conexiones para que las entradas dadas se asignen a las respuestas correctas.



#### ILUSTRACIÓN 10 ESQUEMA DE REDES NEURONALES

Las neuronas entre la capa de entrada y la de salida de una red neuronal se denominan capas ocultas. Las redes neuronales superficiales suelen tener pocas capas ocultas, mientras que las redes neuronales profundas (deep neural networks) tienen más capas ocultas, pudiendo llegar a tener cientos de ellas.

Las redes neuronales pueden configurarse para resolver problemas de clasificación o regresión al colocar una capa de salida específica (de clasificación o regresión) al final de la red. Para tareas de aprendizaje profundo, como el reconocimiento de imágenes, es posible utilizar modelos de aprendizaje profundo ya entrenados.

Tipos comunes de redes neuronales profundas son las redes neuronales convolucionales (CNNs) y las redes neuronales recurrentes (RNNs).

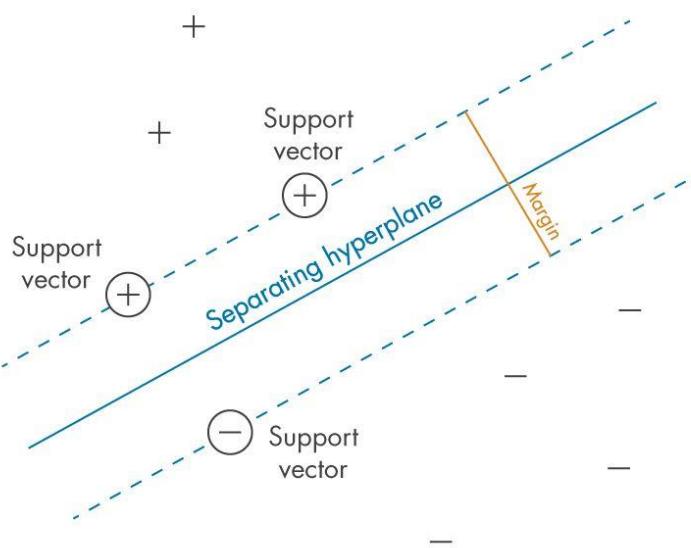
### 3.2.1.1.5 SVM (SUPPORT VECTOR MACHINE)

Un SVM (Support Vector Machine) clasifica los datos encontrando el límite de decisión lineal (hiperplano) que separa los puntos de datos de una clase de los de otra clase. El mejor hiperplano para un SVM es aquel que tiene el mayor margen entre las dos clases cuando los datos son linealmente separables. Si los datos no son linealmente separables, se utiliza una función de pérdida que penaliza los puntos en el lado incorrecto del hiperplano.

Los SVM a menudo emplean una transformación de kernel para proyectar los datos no linealmente separables en un espacio de dimensiones superiores, donde se puede encontrar un límite de decisión lineal.

En cuanto a los algoritmos de regresión SVM, funcionan de manera similar a los algoritmos de clasificación SVM, pero están modificados para predecir respuestas continuas. Estos algoritmos buscan un modelo que se desvíe lo menos posible de los datos medidos mientras minimizan los valores de los parámetros, lo que ayuda a reducir la sensibilidad a los errores.

El objetivo del algoritmo SVM es encontrar un hiperplano que separe de la mejor forma posible dos clases diferentes de puntos de datos. De la mejor forma posible implica el hiperplano con el margen más amplio entre las dos clases, representado por los signos más y menos en la siguiente figura. El margen se define como la anchura máxima de la región paralela al hiperplano que no tiene puntos de datos interiores. El algoritmo solo puede encontrar este hiperplano en problemas que permiten separación lineal. En la mayoría de los problemas prácticos, el algoritmo maximiza el margen flexible permitiendo un pequeño número de clasificaciones erróneas.



#### **ILUSTRACIÓN 11 HIPERPLANO EN EL MODELO SVM**

Definición del margen entre clases: el criterio que los SVM intentan optimizar.

Los vectores de soporte hacen referencia a un subconjunto de las observaciones de entrenamiento que identifican la ubicación del hiperplano de separación. El algoritmo SVM estándar está formulado para problemas de clasificación binaria; los problemas multiclase normalmente se reducen a una serie de problemas binarios.

Específicamente, support vector machines pertenecen a una clase de algoritmos de machine learning denominados métodos kernel, donde se puede utilizar una función de kernel para transformar las características. Las funciones de kernel asignan los datos a un espacio dimensional diferente, que suele ser superior, con la expectativa de que resulte más fácil separar las clases después de esta transformación, simplificando potencialmente los límites de decisión complejos no lineales para hacerlos lineales en el espacio dimensional de características superior asignado. En este proceso, los datos no se tienen que transformar explícitamente, lo que supondría una alta carga computacional. Esto se conoce como truco de kernel. Matlab admite varios kernels, entre ellos:

Tipo de SVM	Kernel de Mercer	Descripción
Función de base radial (RBF) o gaussiana	$K(x, x') = \exp\left(-\frac{\ x - x'\ ^2}{2\sigma^2}\right)$	Aprendizaje de una clase, $\sigma$ representa la anchura del kernel
Lineal	$K(x, x') = x \cdot x'$	Aprendizaje de dos clases
Polinómica	$K(x, x') = (\gamma \cdot x \cdot x' + r)^d$	$\rho$ representa el orden del polinomio
Sigmoide	$K(x, x') = \tanh(\gamma \cdot x \cdot x' + r)$	Representa un kernel de Mercer solo para determinados valores $\beta_0$ y $\beta_1$

**TABLA 2 COMPARACIÓN DE MODELOS SVM**

Dónde:

- $\gamma$ : Escala el producto escalar o distancia entre los puntos.
- $\sigma$ : Define la sensibilidad o ancho de la función (en kernels gaussiano, exponencial, laplaciano, y Cauchy).
- $r$ : Ajuste de sesgo para desplazar los valores (presente en kernels polinómico y sigmoidal).
- $d$ : Grado del polinomio (sólo en el kernel polinómico).
- $x$  y  $x'$  pueden ser vectores unidimensionales o multidimensionales, dependiendo del problema.
- $K(x, x')$ : función Kernel

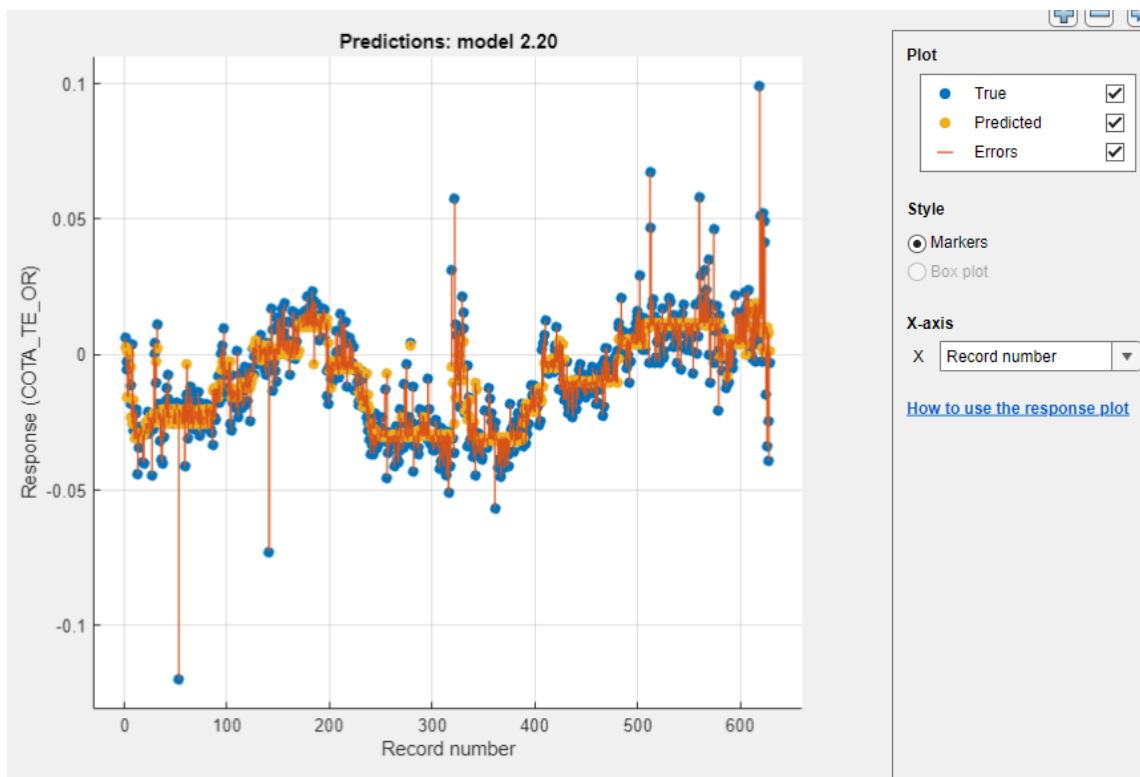
El entrenamiento de support vector machine se asemeja a resolver un problema de optimización cuadrática para ajustar un hiperplano que minimice el margen flexible entre las clases. El número de características transformadas está determinado por el número de vectores de soporte.

Puntos clave:

- Support vector machines son muy populares y logran un buen rendimiento en muchas tareas de clasificación y regresión.
- Aunque los algoritmos SVM están formulados para la clasificación binaria, los algoritmos SVM multiclasa se construyen combinando varios clasificadores binarios.
- Los kernels hacen que los SVM sean más flexibles y capaces de gestionar problemas no lineales.
- Para construir la superficie de decisión, solo se requieren los vectores de soporte seleccionados a partir de los datos de entrenamiento. Una vez terminado el entrenamiento, el resto de los datos de entrenamiento es irrelevante, produciendo una representación compacta del modelo que es adecuada para generar código de forma automatizada.

### 3.2.1.2 GRÁFICA DE RESPUESTA

A la hora de hacer los entrenamientos de modelos de regresión, la gráfica de respuesta muestra los valores de la respuesta que verdaderamente se da (respuesta real) y los valores de las predicciones que el modelo ha realizado durante dicho entrenamiento. Con esta gráfica se puede visualizar cuánto distan las predicciones de los valores reales mediante la pestaña de visualización de error. Más allá del resumen con los valores RMSE y los demás indicadores esto permite visualizar los resultados de manera más visual e intuitiva.



**ILUSTRACIÓN 12 GRÁFICA QUE MUESTRA LOS VALORES REALES, LAS PREDICCIÓNES Y LOS ERRORES DE ENTRENAMIENTO COMETIDOS**

### 3.2.1.3 SUMARIO

El resumen implementa los resultados obtenidos en la gráfica de manera numérica. Aparecen todos los indicadores de validación del modelo (RMSE, R<sup>2</sup>, MSE, MAE, MAPE) sin embargo nos centramos en los indicadores del RMSE y de R<sup>2</sup> ya que son suficientes para ver cómo de bien se comporta el modelo tanto en el entrenamiento como en el test con datos desconocidos. Además de esto indica el modelo empleado con el resto de hiperparámetros que se pueden variar antes de hacer los entrenamientos.

**Model 2.20: Gaussian Process Regression**  
Status: Trained

**Training Results**

RMSE (Validation) 0.013301  
R-Squared (Validation) 0.57  
MSE (Validation) 0.00017692  
MAE (Validation) 0.0088780  
MAPE (Validation) 213.4%  
Prediction speed ~11000 obs/sec  
Training time 11.683 sec  
Model size (Compact) ~39 kB

▼ Model Hyperparameters

Preset: Exponential GPR  
Basis function: Constant  
Kernel function: Exponential  
Use isotropic kernel: Yes  
Kernel scale: Automatic  
Signal standard deviation: Automatic  
Sigma: Automatic  
Standardize data: Yes  
Optimize numeric parameters: Yes

► Feature Selection: 5/5 individual features selected

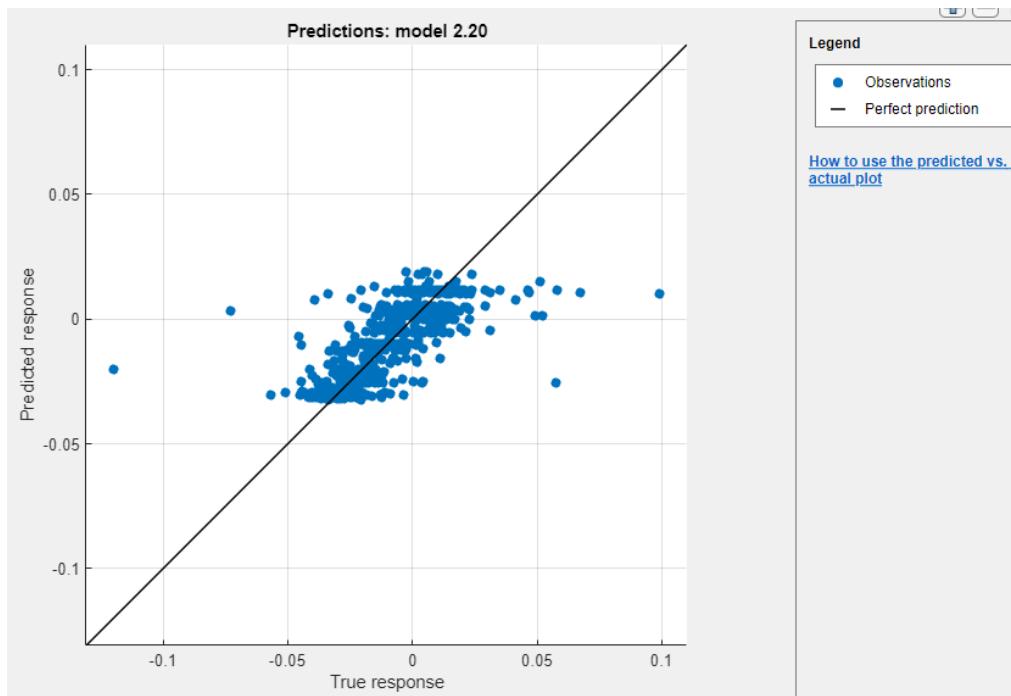
► PCA: Disabled

► Optimizer: Not applicable

**ILUSTRACIÓN 13 RESUMEN DE LOS RESULTADOS TRAS REALIZAR ENTRENAMIENTOS Y TESTEOS**

**3.2.1.4 PREDICCIÓN PERFECTA VS PREDICCIÓN**

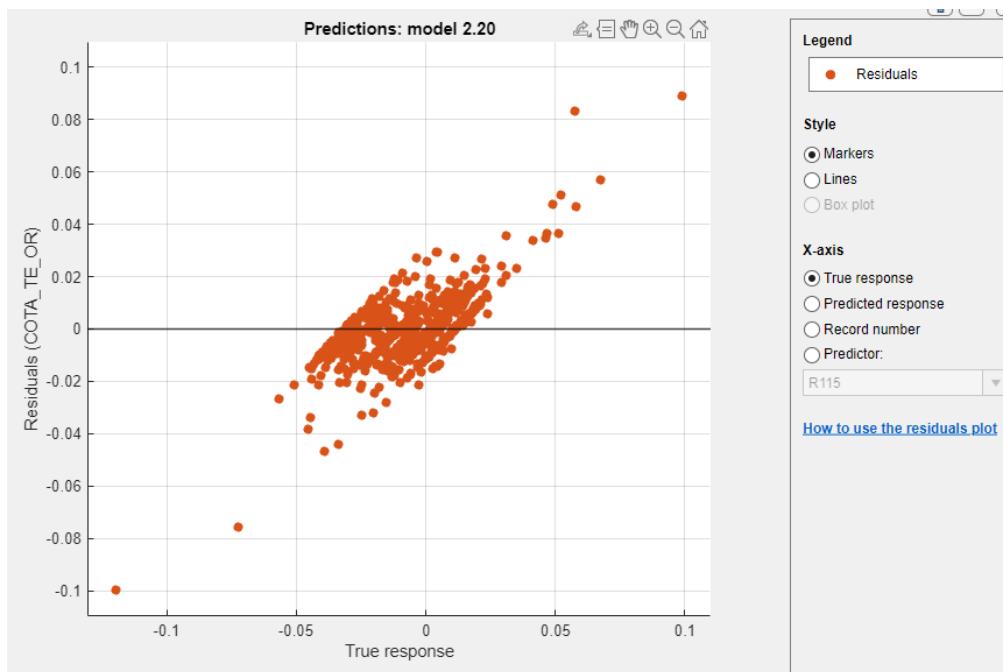
La gráfica siguiente es otra manera de visualizar cómo de buena es la predicción que se está haciendo. Cuanto más se aproximen los puntos a la recta, mejor es la predicción. Se están comparando las predicciones con las predicciones si estas fueran perfectas, es decir los resultados reales.



**ILUSTRACIÓN 14 GRÁFICA DE OBSERVACIONES FRENTE A LA PREDICCIÓN PERFECTA**

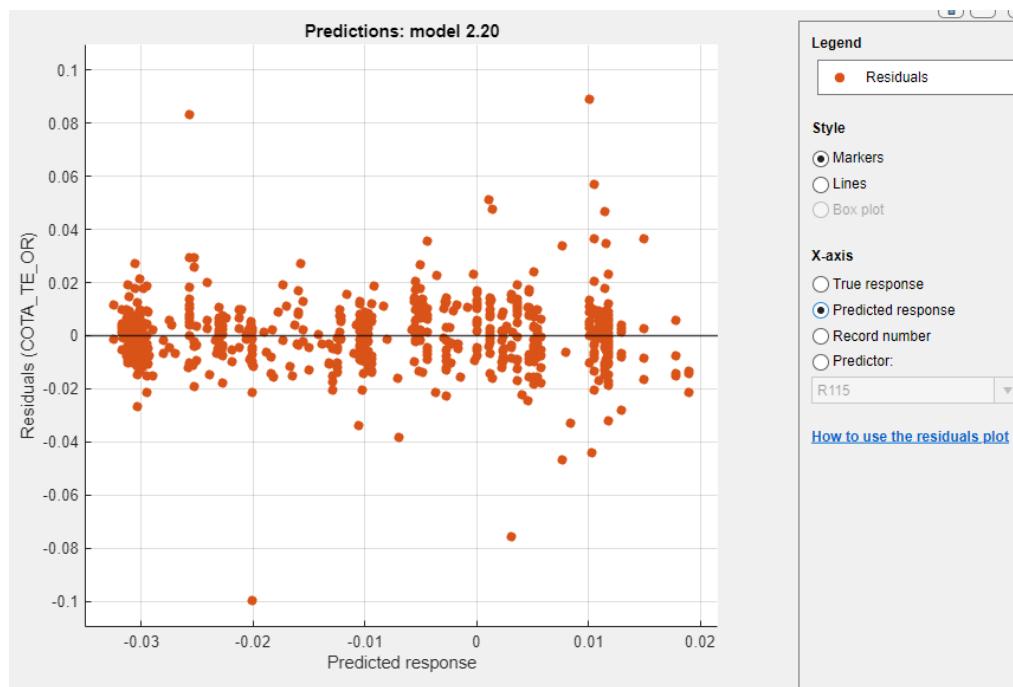
### 3.2.1.5 GRÁFICAS DE RESIDUOS

La gráfica correspondiente permite visualizar de manera gráfica la dispersión de residuos a la hora de entrenar con respecto a los resultados reales. Esto permite visualizar de manera gráfica los valores de residuo máximo en valor absoluto y cuáles son los valores típicos encontrados en la respuesta real.



**ILUSTRACIÓN 15 GRÁFICA DE RESIDUOS RMSE CON RESPECTO A LA RESPUESTA REAL**

La gráfica correspondiente permite visualizar de manera gráfica la dispersión de residuos a la hora de entrenar con respecto a las predicciones. Esto permite visualizar de manera gráfica los valores de residuo máximo en valor absoluto y cuáles son los valores típicos encontrados en las predicciones.



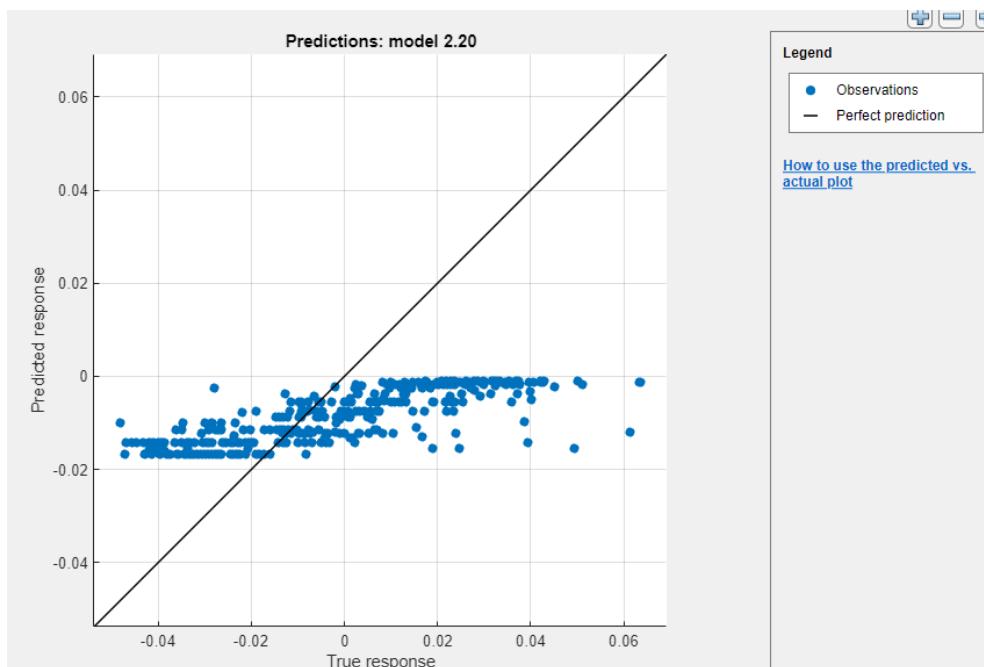
**ILUSTRACIÓN 16 GRÁFICA DE RESIDUOS RMSE CON RESPECTO A LAS PREDICCIONES**

### 3.2.2 TEST

En este apartado se abordan las herramientas útiles a la hora de hacer test con los modelos.

#### 3.2.2.1 PREDICCIÓN PERFECTA VS PREDICCIÓN DEL TEST

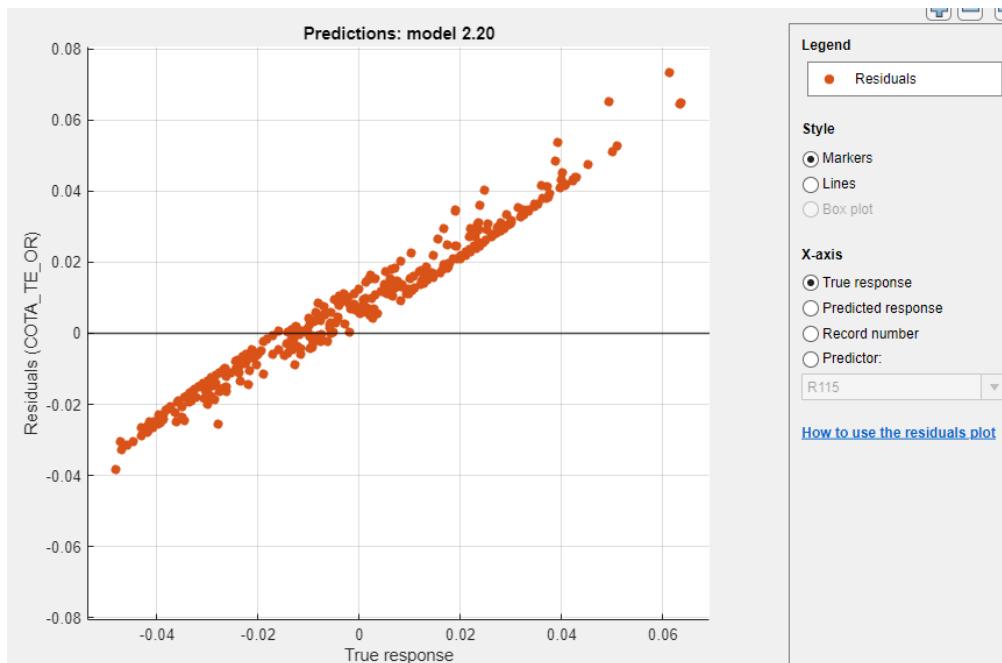
La siguiente gráfica muestra lo mismo que en el caso de los entrenamientos pero en este caso con respecto al test.



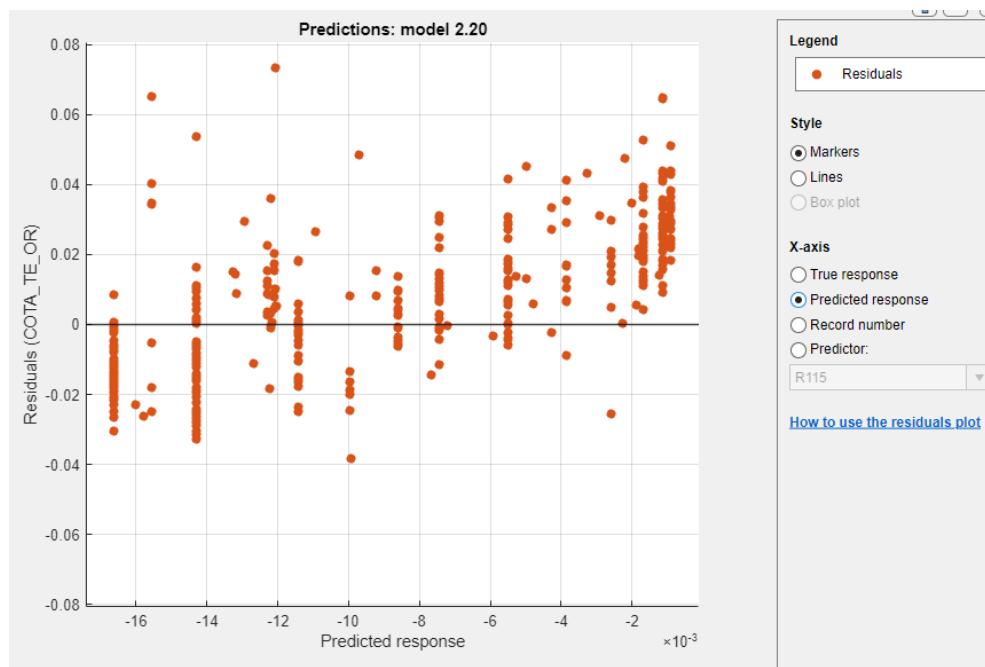
**ILUSTRACIÓN 17 GRÁFICA DE OBSERVACIONES FRENTE A LA PREDICCIÓN PERFECTA (TEST)**

### 3.2.2.2 GRÁFICAS DE RESIDUOS DEL TEST

Las siguientes gráficas indican lo mismo que en el caso anterior (entrenamiento) pero esta vez con el test del modelo.



**ILUSTRACIÓN 18 GRÁFICA DE RESIDUOS RMSE CON RESPECTO A LA RESPUESTA REAL (TEST)**



**ILUSTRACIÓN 19 GRÁFICA DE RESIDUOS RMSE CON RESPECTO A LAS PREDICIONES**

### 3.2.2.3 TABLAS DE RESULTADOS

Una vez realizados los entrenamientos y los test, la siguiente tabla nos resume todos los resultados de todos los modelos que se han entrenado y testeado para poder compararlos y encontrar cual es el mejor de una manera más fácil.

RMSE (Validation)	MSE (Validation)	RSquared (Validation)	MAE (Validation)	MAE (Test)	MSE (Test)	RMSE (Test)	RSquared (Test)
0.013468	0.00018139	0.56278	0.0088848	0.014722	0.00035519	0.018846	0.40175
0.013873	0.00019247	0.53608	0.0094683	0.011754	0.00025865	0.016083	0.56435
0.052182	0.0027229	-5.5634	0.011673	0.16385	0.3573	0.59774	-600.81
0.01389	0.00019294	0.53494	0.0094662	0.0118	0.00028283	0.016818	0.52362
0.013931	0.00019408	0.53219	0.0094958	0.012041	0.00028042	0.016746	0.52769
0.013468	0.00018139	0.56278	0.0088848	0.014722	0.00035519	0.018846	0.40175
0.013722	0.00018829	0.54615	0.0092059	0.014085	0.00033047	0.018179	0.44338
0.013872	0.00019244	0.53614	0.0094138	0.013205	0.00030642	0.017505	0.48389
0.013888	0.000019288	0.53508	0.0094848	0.011915	0.00026427	0.016256	0.55488
0.015595	0.00024321	0.41375	0.010042	0.017162	0.00095042	0.030829	-0.60083
0.016165	0.00026113	0.37016	0.010424	0.088798	0.11875	0.3446	-199.02
0.013636	0.000018593	0.55182	0.0089991	0.022358	0.00074655	0.027323	-0.25744
0.014001	0.000019603	0.52748	0.0094857	0.013798	0.00033296	0.018247	0.43918
0.014019	0.000019654	0.52626	0.0096502	0.011592	0.00024227	0.015565	0.59194
0.020368	0.000041486	8.1944e-06	0.016373	0.021317	0.00067497	0.02598	-0.13688
0.020407	0.000041643	-0.0037616	0.016416	0.021382	0.00067957	0.026069	-0.14462
0.013403	0.000017965	0.56697	0.0089359	0.014304	0.00033186	0.018217	0.44103
0.013456	0.000018105	0.56359	0.0090104	0.01401	0.00031334	0.017701	0.47224
0.01373	0.00001885	0.54563	0.0092942	0.010769	0.00022239	0.014913	0.62542
0.013382	0.000017909	0.56832	0.0089202	0.021839	0.00071816	0.026798	-0.20961
0.013301	0.000017692	0.57355	0.008878	0.017519	0.00047771	0.021857	0.19537
0.013332	0.000017773	0.57159	0.0088935	0.018559	0.00052934	0.023007	0.10841
0.016462	0.000027099	0.3468	0.010472	0.067956	0.0087481	0.093531	-13.735
0.014991	0.000022472	0.45834	0.0096272	0.04338	0.0032753	0.05723	-4.5167
0.022504	0.000050641	-0.22066	0.010041	0.04469	0.0035775	0.059812	-5.0257
0.014933	0.000022298	0.46252	0.0095843	0.041745	0.0036647	0.060537	-5.1726
0.014769	0.000021814	0.4742	0.0093956	0.039907	0.0025979	0.05097	-3.3757

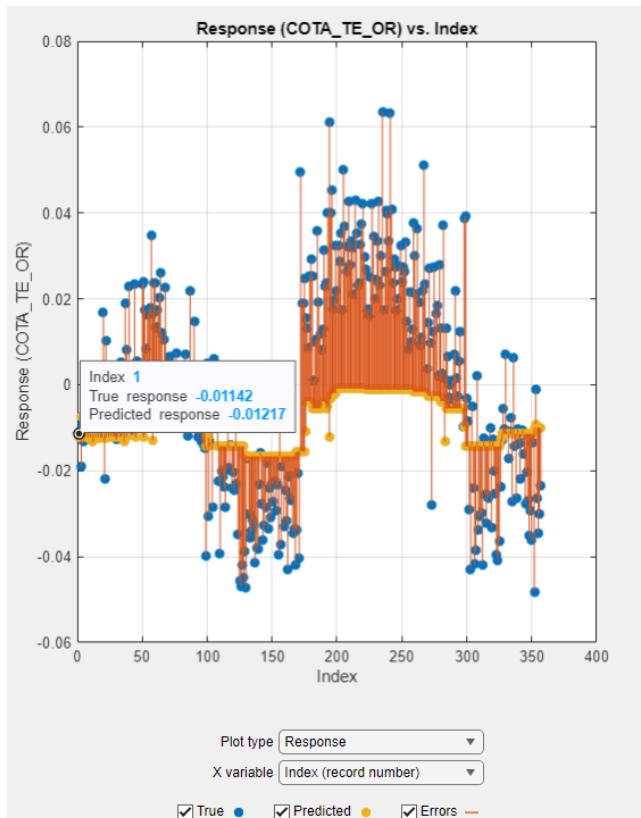
**TABLA 3 GENERAL DE LOS RESULTADOS DE LOS ENTRENAMIENTOS Y DE LOS TEST CON SUS RESPECTIVOS INDICADORES**

### 3.2.3 EXPLAIN

Las siguientes herramientas explicativas sirven para determinar en qué grado afectan las variables al modelo y como las interacciones entre ellas pueden afectar a dicho modelo.

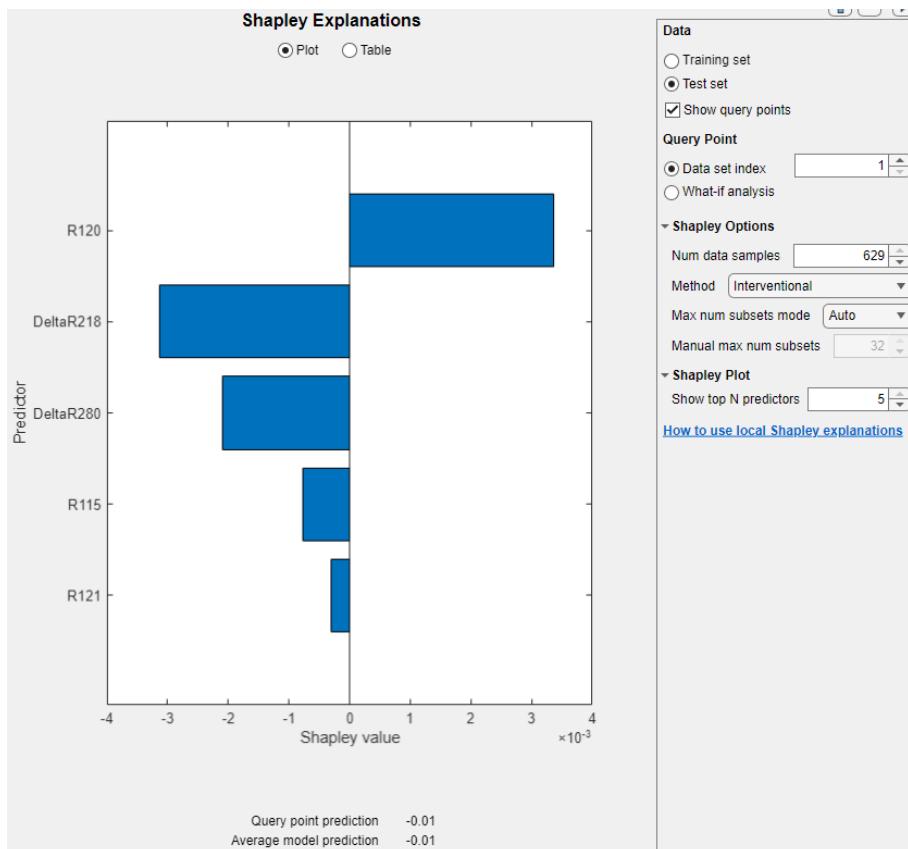
#### 3.2.3.1 SHAPLEY

El valor de Shapley en Machine Learning mide la contribución marginal de cada característica al rendimiento del modelo, distribuyendo de manera justa la predicción final en función del impacto de cada característica en diferentes combinaciones posibles. Este enfoque resulta particularmente útil para interpretar modelos, ya que permite comprender cómo y por qué se generan ciertas predicciones, especialmente en modelos complejos como redes neuronales o bosques aleatorios, donde las relaciones entre características y resultados no son evidentes. Además, el valor de Shapley identifica qué características tienen un efecto positivo o negativo en las predicciones, ofreciendo información clave sobre su importancia. También facilita la visualización de estos valores, mejorando la comunicación con las partes interesadas y apoyando la toma de decisiones. Asimismo, es una herramienta valiosa para validar modelos, asegurando que las decisiones sean coherentes con el conocimiento del dominio y detectando posibles problemas en el modelo o en los datos. Por último, permite comparar diferentes modelos en términos de cómo utilizan las características, ayudando a seleccionar el más adecuado para un problema específico.



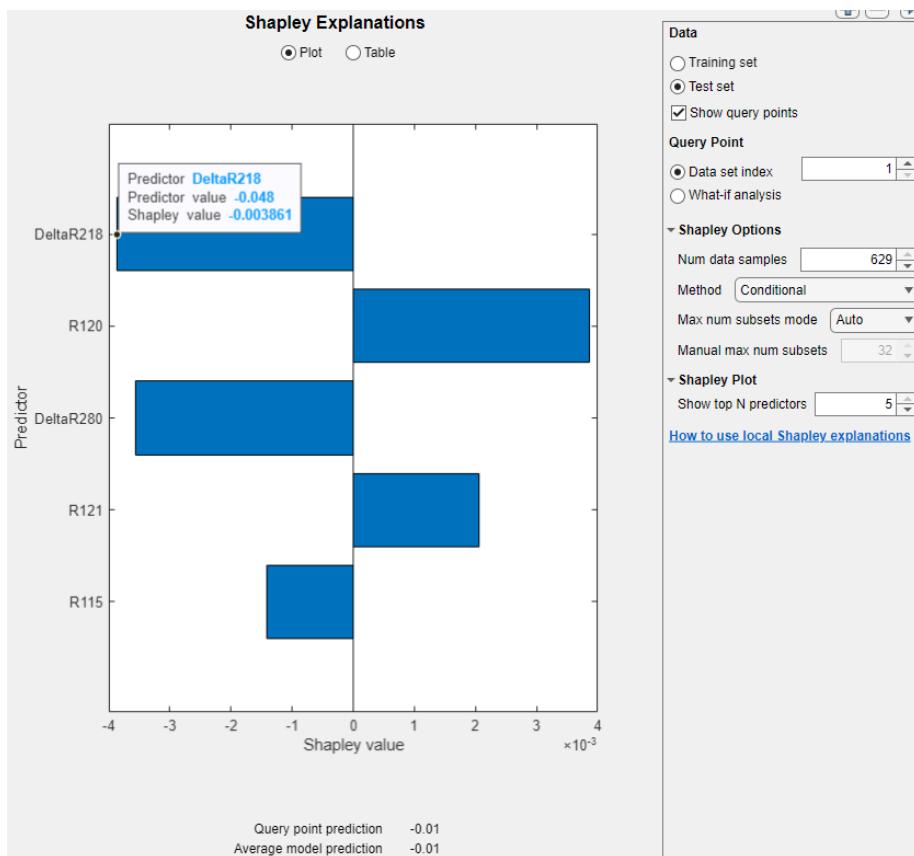
**ILUSTRACIÓN 20 GRÁFICA DE RESPUESTA EN FUNCIÓN DE LAS VARIABLES DEL MODELO**

A continuación la siguiente gráfica muestra el método Shapley intervencional, es decir que no tiene en cuenta las dependencias entre variables. Como se puede observar en la siguiente gráfica la variable R120 afecta positivamente al output del modelo incrementando su valor cuando esta variable lo hace. Para el resto de las variables pasa justo lo contrario, cuando aumentan estas hacen que la salida decrezca.



**ILUSTRACIÓN 21 GRÁFICA DEL SHAPLEY INTERVENCIONAL**

A continuación, la siguiente gráfica muestra el método Shapley condicional, es decir que esta vez sí que tiene en cuenta las dependencias entre variables. Como se puede observar en la siguiente gráfica la variable R120 sigue afectando positivamente al output del modelo incrementando su valor cuando esta variable lo hace. Sin embargo, ya no es la que más influye en este output, ahora es la variable DeltaR218. Por lo que podemos decir que al tener en cuenta estas dependencias entre variables, se puede modificar también el grado en que estas afectan al output o resultado final de la variable de salida.



**ILUSTRACIÓN 22 GRÁFICA DEL SHAPLEY INTERVENCIONAL**

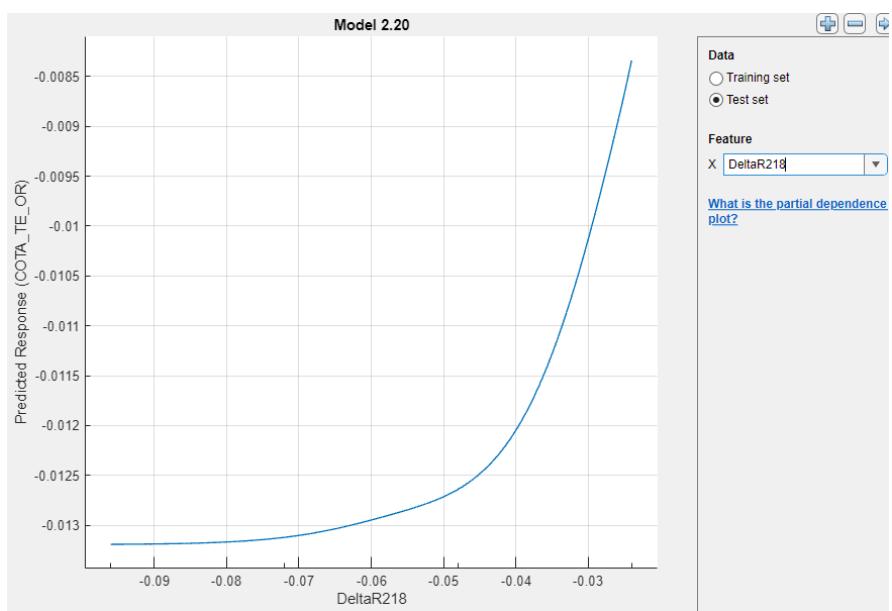
### 3.2.3.2 LIME

LIME (Local Interpretable Model-agnostic Explanations) es una técnica diseñada para proporcionar explicaciones locales de las predicciones realizadas por modelos de machine learning complejos. Su principal enfoque es generar modelos simples e interpretables, como una regresión lineal, que aproximen las predicciones de modelos más sofisticados para casos específicos. Para lograrlo, LIME introduce perturbaciones en los datos de entrada cercanos a la instancia que se desea analizar y observa cómo estas afectan las predicciones. Con estos datos perturbados y sus resultados, entrena un modelo interpretable para explicar la predicción original. Este método es especialmente útil para entender cómo las características específicas afectan las predicciones de un modelo en instancias particulares, brindando explicaciones locales en lugar de globales, lo que permite un análisis más detallado en contextos concretos. Además, al ser independiente del tipo de modelo, LIME puede aplicarse a cualquier técnica de machine learning, como redes neuronales, árboles de decisión o modelos de ensamble, lo que lo hace versátil y ampliamente aplicable. También facilita la creación de visualizaciones que destacan la importancia de cada característica para una predicción específica, mejorando la comunicación con partes interesadas. Por último, LIME es una herramienta eficaz para validar modelos, ya que permite verificar si las decisiones se basan en características relevantes o si, por el contrario, se apoyan en correlaciones espurias, lo que podría indicar problemas en el modelo o en los datos. Este método es más rápido computacionalmente que el Shapley, sin embargo tiene

menos precisión. Las herramientas que proporciona funcionan de manera similar a las vistas anteriormente en el Shapley.

### 3.2.4 DEPENDENCIA PARCIAL

La dependencia parcial (Partial Dependence) es una herramienta clave en machine learning para interpretar modelos complejos, particularmente aquellos que pueden ser difíciles de entender, como bosques aleatorios, árboles de decisión y modelos de ensamble. Su principal utilidad radica en analizar y visualizar cómo una o más características afectan las predicciones del modelo, manteniendo el resto de las características constantes. Esto permite a los analistas entender la relación entre las variables independientes y la variable objetivo, incluso en casos donde dichas relaciones son no lineales o contraintuitivas. Además, ofrece la posibilidad de generar gráficos que ilustran cómo varía la predicción del modelo al modificar una característica específica, lo que facilita la comunicación de los resultados. Por ejemplo, se podría graficar la influencia de los ingresos sobre la probabilidad de compra de un cliente. También puede ser útil para identificar interacciones entre variables, ya que los patrones observados en las curvas de dependencia pueden cambiar en función de los valores de otras características. Finalmente, la dependencia parcial es una herramienta valiosa para validar el modelo, ayudando a verificar si las relaciones capturadas por el modelo son coherentes con las expectativas del dominio. Relaciones inesperadas en estos análisis pueden ser indicativas de problemas en los datos o en la construcción del modelo.



**ILUSTRACIÓN 24 GRÁFICA DE DEPENDENCIA PARCIAL**

## 4. DESCRIPCIÓN DEL PROCESO DE FABRICACIÓN MULTIETAPA

En esta sección se desarrollan los procesos de fabricación de rodamientos, desde el rodamiento en sí hasta el modelo de funcionamiento de todas las estaciones de la línea de producción con el gemelo digital.

***Nota: En esta sección 4 se han sintetizado datos provenientes del proyecto Fandango***

### 4.1 RODAMIENTOS

Los rodamientos son componentes mecánicos que permiten el movimiento relativo entre dos partes, reduciendo la fricción entre ellas. Se componen generalmente de una serie de elementos rodantes (como bolas o rodillos) que se encuentran entre dos superficies, llamadas anillos o carreras. Los rodamientos son cruciales en muchas aplicaciones industriales y en el funcionamiento de máquinas y vehículos, como los camiones en este caso.

#### 4.1.1 TIPO

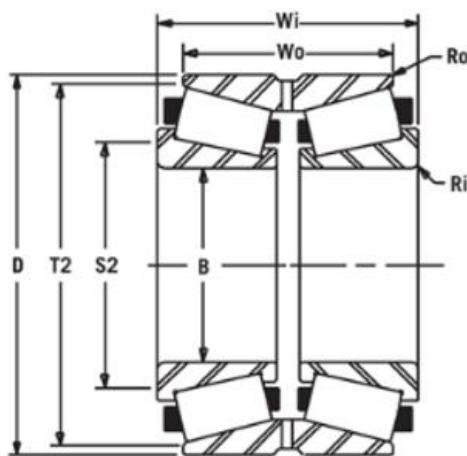
Los rodamientos objeto de estudio en este trabajo son del tipo: rodillos cónicos de doble fila. Un rodamiento de anillos bicónicos, o rodamiento de rodillos cónicos de doble fila, está compuesto por varias partes esenciales que trabajan en conjunto para soportar cargas radiales y axiales de manera eficiente. Los anillos exterior e interior contienen las pistas de rodadura, que son superficies cónicas diseñadas para alojar los rodillos cónicos, los cuales permiten el movimiento relativo entre los anillos. Los rodillos están dispuestos en dos filas, lo que mejora la capacidad de carga del rodamiento y asegura un soporte adecuado en aplicaciones exigentes. La jaula o separador mantiene los rodillos equidistantes, evitando el contacto directo entre ellos y garantizando un movimiento uniforme.

En algunos diseños, un IRU (unidad de retención interna) se incluye para mejorar la estabilidad del conjunto, asegurando la correcta alineación de las piezas. Además, pueden incorporarse sellos para proteger el rodamiento de contaminantes externos y mantener el lubricante, ya sea grasa o aceite, en su interior, reduciendo la fricción y el desgaste. Este diseño permite a los rodamientos de anillos bicónicos manejar altas cargas combinadas con precisión y durabilidad, lo que los hace ideales para aplicaciones industriales y automotrices.



**ILUSTRACIÓN 25 RODAMIENTOS DE RODILLOS CÓNICOS DE DOBLE FILA (O BICÓNICO)**

*Archivo fuente: [MESIC\\_presentation](#)*



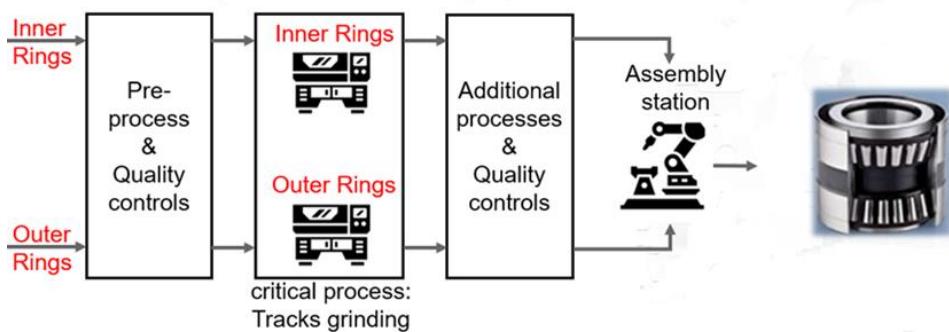
**ILUSTRACIÓN 26 RODAMIENTO DE RODILLOS CÓNICOS DE DOBLE FILA (O BICÓNICO)**

*Archivo fuente: [MESIC\\_presentation](#)*

## 4.2 PROCESO DE FABRICACIÓN

### 4.2.1 FASES PRINCIPALES DEL PROCESO

La operación principal de esta línea es el rectificado de las superficies de los distintos componentes que conforman el rodamiento. Este proceso consiste en un mecanizado que utiliza una muela abrasiva, permitiendo alcanzar un alto nivel de precisión dimensional. Tras completar el rectificado de las piezas, estas se ensamblan y se llevan a cabo otras tareas complementarias, como el engrasado o aceitado.



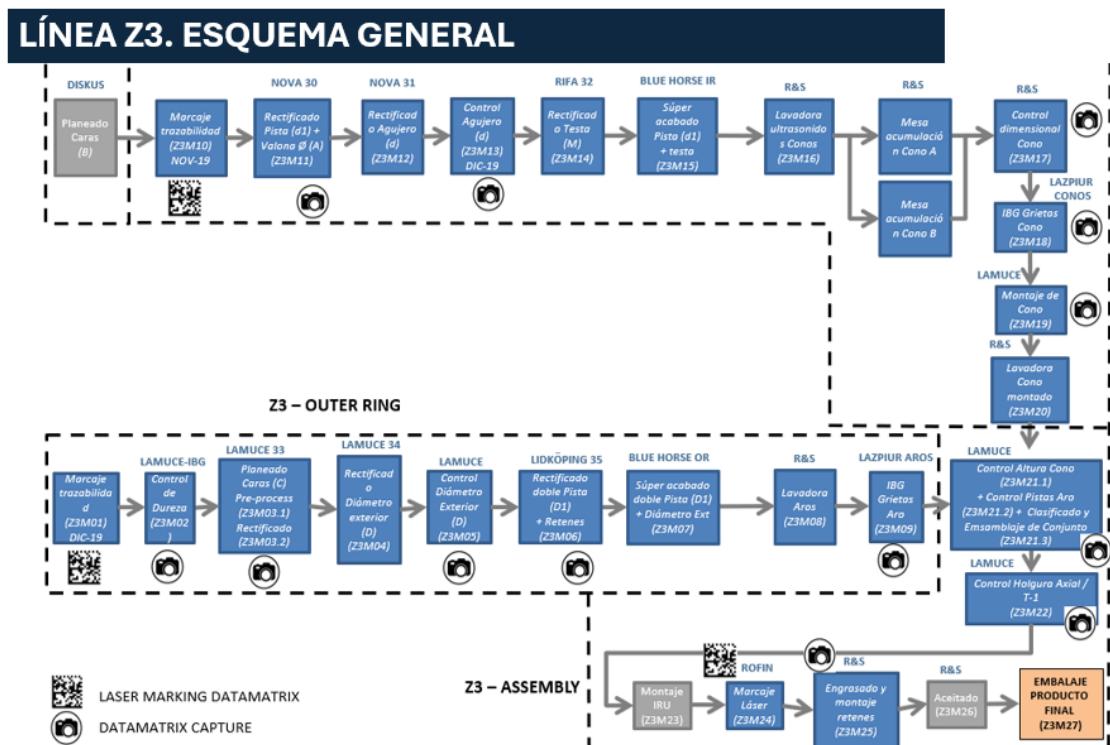
**ILUSTRACIÓN 27 ESQUEMA RESUMIDO DE LA PLANTA DE FABRICACIÓN DE RODAMIENTOS**

*Archivo fuente: [MESIC\\_presentation](#)*

En la sección Z3, los conos (o aros interiores) y los aros exteriores se procesan de manera independiente en dos ramas separadas. En la etapa final de la línea, los conos y los aros exteriores se ensamblan para formar el rodamiento, sobre el cual se realizan las operaciones finales necesarias. La línea de producción se divide en tres secciones. Dos de ellas son paralelas entre sí y la tercera, al final de la línea, es el resultado de la unión de las otras dos.

Las secciones paralelas están dedicadas a los procesos de rectificado del anillo exterior y de los dos anillos internos, respectivamente. Estas secciones están formadas por varias estaciones, como controles dimensionales, procesos de superacabado, estaciones de lavado y la estación de rectificado en sí. Las dos estaciones de rectificado son el núcleo de ambas secciones paralelas, ya que es en estas estaciones donde se ajustan las dimensiones críticas. La unión de las secciones paralelas es un área de almacenamiento y emparejamiento donde los anillos exteriores e internos se clasifican en 20 grupos y luego se emparejan para formar el rodamiento. Si la estación encuentra los pares necesarios para formar el conjunto en el área de almacenamiento, el anillo recibido se empareja en lugar de ser almacenado. Sin embargo, si la estación no puede encontrar los pares necesarios en el área de almacenamiento, el anillo recibido se almacena en esta área hasta que se reciban los pares adecuados. Para emparejar los anillos internos y externos, deben pertenecer a grupos similares ( $G \pm 2$ ).

Desde este punto hasta el final de la línea, el conjunto se verifica dimensionalmente, se engrasa, se aceita y se empaqueta. También es importante mencionar que la estación de rectificado del anillo interno es el cuello de botella de todo el proceso.

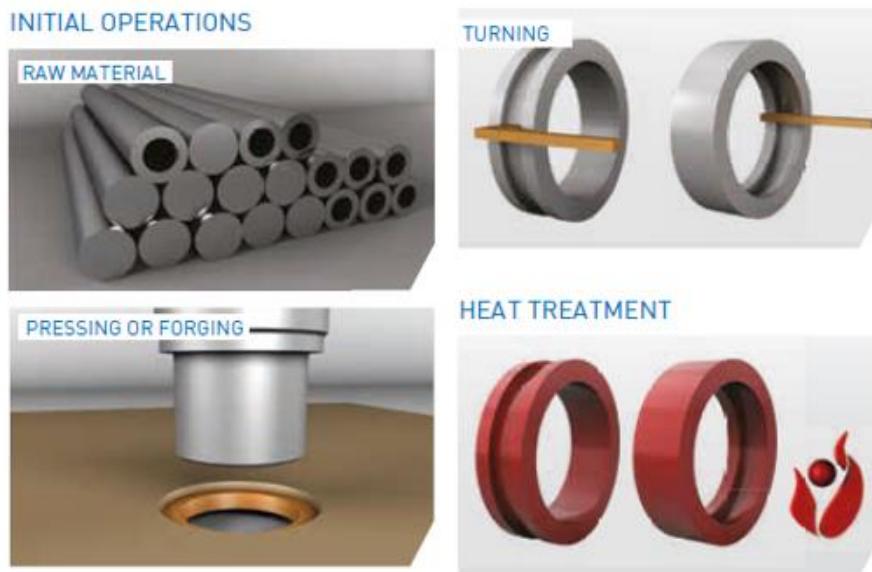


#### ILUSTRACIÓN 28 LÍNEA DE PRODUCCIÓN COMPLETA CON SUS 3 ESTACIONES PRINCIPALES

Archivo fuente: Resumen proceso producción Z3

## 4.2.2 PROCESOS

Se parte de barras macizas o de tubos de acero que son cortadas o forjadas para luego obtener tanto los conos como los aros. Estos se someten primero a un proceso de torneado y posteriormente a un tratamiento térmico para mejorar las propiedades del material de la pieza. Después, con respecto a los conos, se procede a rectificar las diferentes caras de la pieza (la valona, la pista y la cara estrecha), luego se hace el rectificado interior y finalmente se somete a un superacabado. Se procede en con el mismo orden de procesos para el aro. La fabricación de rodamientos requiere procesos de producción de alta precisión. Es necesario garantizar no solo la composición y dureza del material, sino también las dimensiones geométricas micrométricas. Los errores de fabricación causarán problemas relacionados con la rugosidad de la superficie, ondulación, carreras desalineadas y elementos rodantes fuera de tamaño. Todos estos factores afectan la fatiga, que es el modo de falla predominante de los rodamientos. Los rodamientos de rodillos cónicos pueden soportar altas cargas radiales, así como altas cargas axiales. Tienen cuatro componentes principales: anillo interior, anillo exterior, rodillos y jaula. Los siguientes procesos se muestran en las siguientes ilustraciones:



**ILUSTRACIÓN 29 PROCESOS INICIALES DE FABRICACIÓN DE AROS Y CONOS**

Archivo fuente: [MESIC\\_presentation](#)



**ILUSTRACIÓN 30 PROCESOS DE FABRICACIÓN DE AROS Y CONOS**

Archivo fuente: [MESIC\\_presentation](#)

### 4.2.3 FABRICACIÓN DE AROS

El proceso de rectificado de los aros, al igual que en el caso de los conos, se descompone en varios subrectificados llevados a cabo en diferentes estaciones. Se detallan dichas estaciones y las variables registradas en cada una en:

*ANEXO 2→FABRICACIÓN DE CONOS Y AROS→AROS*

### 4.2.4 FABRICACIÓN DE CONOS

El proceso de rectificado de conos está compuesto por varias etapas consecutivas, realizadas en diferentes máquinas dentro de la línea de producción. Se describen los pasos llevados a cabo en cada estación dentro de la zona de rectificado de conos en:

*ANEXO 2→FABRICACIÓN DE CONOS Y AROS→CONOS*

### 4.2.5 ENSAMBLAJE Y ALMACENAMIENTO

En esta sección de la línea, se llevan a cabo las etapas finales de ensamblaje y control de calidad de los conjuntos, sin realizar operaciones de mecanizado adicionales. La mayoría de las estaciones correspondientes se describen en:

*ANEXO 2→ FABRICACIÓN DE CONOS Y AROS→ENSAMBLAJE Y ALMACENAMIENTO*

#### 4.2.5.6 ESTACIÓN LAMUCE DE ENSAMBLADO DEL CONJUNTO (Z3M21)

Esta estación une los conjuntos interiores con los aros exteriores, formando el rodamiento final con una holgura axial dentro de las tolerancias especificadas.

Estructura de la estación:

- Medida de aros: Clasificación de aros exteriores.
- Medida de conos: Clasificación de conjuntos interiores.
- Ensamblaje: Unión final de los componentes clasificados.

La estación incluye una mesa acumuladora para piezas ya medidas y listas para ensamblarse.

Clasificación de conos por  $T_{i\_inversa}$  (Tinv)

- La estación identifica el tipo de cono (A o B) y mide su  $T_{i\_inversa}$  utilizando un aro patrón.
- Los conos son clasificados en 20 familias con un rango de 4  $\mu\text{m}$  cada una, basándose en los valores obtenidos de  $T_{i\_inversa}$ .

Medición del diámetro de la valona

Para medir el diámetro de la valona, la estación realiza una comparación con un cono patrón. La selección del patrón sigue este esquema:

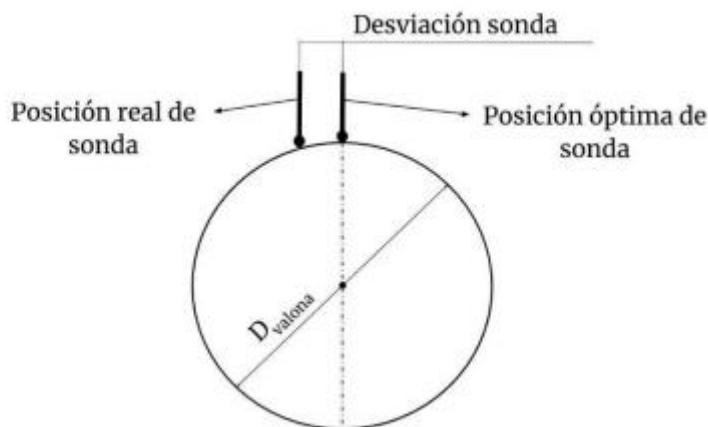
- El patrón utilizado es un cono A.
- Si el cono medido es A, la comparación es directa:  $DesvA = Dcono,A - Dpatrón,A$
- Si el cono es B, el cálculo implica una corrección adicional debido a las diferencias nominales entre los conos A y B:

La máquina mide la desviación total:  $Desvtot,B = Dcono,B - Dpatrón,A$

Corrige esta desviación restando la diferencia nominal almacenada entre ambos tipos de conos ( $Dnom,A - Dnom,B$ ):  $Desv,B = Desvtot,B - (Dnom,A - Dnom,B)$

### Definición de términos

- Desvi: Desviación del cono de tipo i respecto al patrón, devuelta como resultado final por la máquina.
- Desvtot,B: Desviación total medida al comparar un cono B con el patrón A.
- $Dcono,i$ : Diámetro del cono de tipo i.
- $Dpatrón,A$ : Diámetro del patrón (cono A).
- $Dnom,i$ : Diámetro nominal del cono de tipo i.

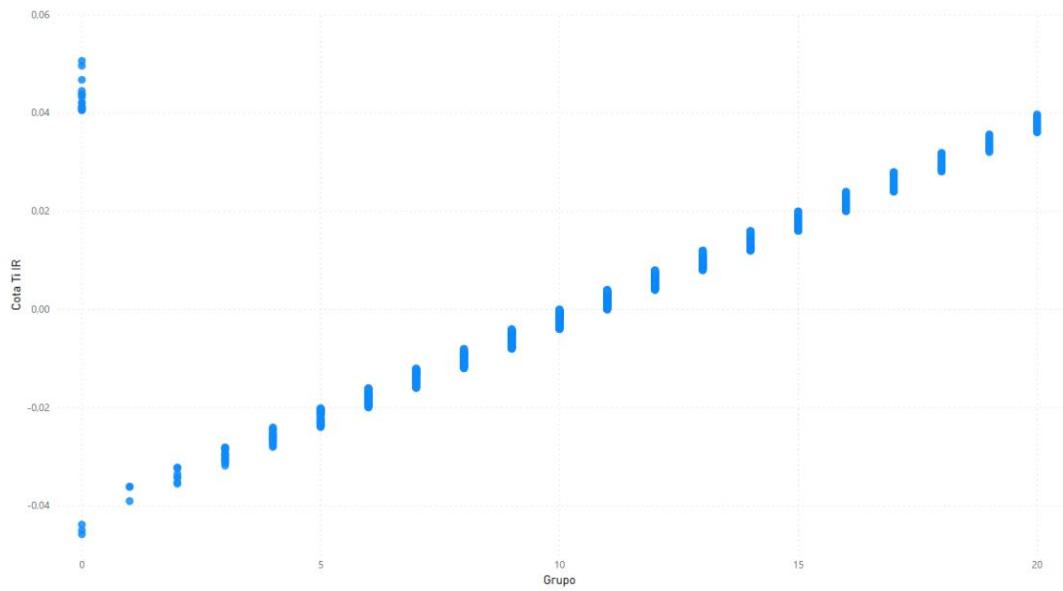


### **ILUSTRACIÓN 31 DESVIACIONES PROBLEMÁTICAS DE LA SONDA AL MEDIR EL DIÁMETRO DE LA VALONA.**

**Archivo fuente: [Resumen proceso producción Z3](#)**

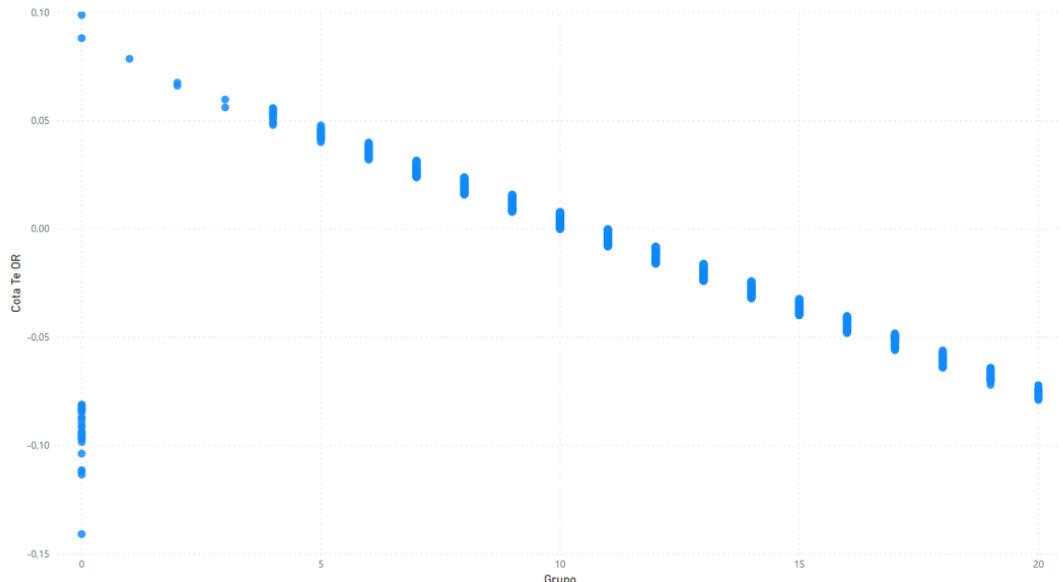
Una vez identificado, medido y clasificado, el cono se almacena en la mesa de acumulación. Si se trata de un cono B, se almacena en la mesa apoyado sobre su cara ancha mientras que si se trata de un cono A, se almacena apoyado sobre su cara estrecha.

Existen 20 familias de conos en función de las medidas y tolerancias:



**ILUSTRACIÓN 32 CLASIFICACIÓN DE LOS CONOS EN 20 FAMILIAS DE 4 MM EN FUNCIÓN DE TIR INVERSA. LA FAMILIA 0 CORRESPONDE A LOS CONOS FUERA DE LOS LÍMITES DE TOLERANCIA.**

Archivo fuente: [Resumen proceso producción Z3](#)



**ILUSTRACIÓN 33 CLASIFICACIÓN DE LOS AROS EN 20 FAMILIAS DE 8 MM EN FUNCIÓN DE LA DISTANCIA ENTRE PISTAS. LA FAMILIA 0 CORRESPONDE A LOS CONOS FUERA DE LOS LÍMITES DE TOLERANCIA.**

Archivo fuente: [Resumen proceso producción Z3](#)

Los componentes rara vez se clasifican en los grupos más extremos (1-3 y 18-20), por lo que el objetivo de los modelos no es mejorar la capacidad del proceso, sino fabricar componentes óptimos para ser emparejados.

La Z3M21.2 es una máquina que clasifica aros exteriores según la distancia entre las pistas, dividiéndolos en 20 familias de 8 µm. La medición se realiza mediante conos patrón que se ajustan sin holgura contra las pistas del aro, determinando la distancia por el punto de contacto.

La Z3M21.3 es una mesa de acumulación y ensamblaje, con capacidad para 220 conos A y B y 110 aros exteriores. La mesa tiene 20 posiciones para el montaje, una por cada familia de aros y conos. El proceso de emparejamiento de conos y aros se realiza según la holgura axial (HA) dentro de las tolerancias, y puede ser de tres tipos:

- Emparejado en recto: los conos A, B y el aro pertenecen a la misma familia.
- Emparejado en V: los conos A y B pertenecen a familias cercanas, con el cono A de una familia menor que el aro y el cono B de una mayor.
- Emparejado en L: se permite una variación de hasta dos familias en uno de los elementos.

La máquina de emparejamiento almacena las combinaciones de familias que generan una HA dentro de la tolerancia. Los conos A y B se fabrican simultáneamente y, por lo general, pertenecen a familias similares. Se utiliza el código datamatrix del aro como identificador del conjunto, ya que los códigos de los conos quedan ocultos tras el aro, permitiendo rastrear los conos emparejados a través del código del aro.

#### 4.2.6 PRINCIPALES VARIABLES E INDICADORES PARA MONITORIZAR

Las siguientes tablas muestran las variables influyentes de los aros y de los conos. Se realizó un análisis para ver cuáles eran estas variables. En este trabajo partimos de esa información recogida en los documentos: [Aros 200826\\_InformeAnalisisVariables](#) y [Conos 200910\\_Patrones\\_fabricacion](#)

##### 4.2.6.1 VARIABLES INFLUYENTES DE AROS

Variable name	Description	Type
R120	Radial adjustment of the grinding wheel	Control variable
R280	Radial position of the wheel during grinding	Factor
R121	Axial adjustment of the grinding wheel	Control variable
R218	Wheel diameter	Factor
R115	Dressing compensation	Factor
$T_c$	Distance between raceways	Output

**TABLA 4 VARIABLES Y FACTORES INFLUYENTES PARA LOS MODELOS DE AROS**

**ARCHIVO FUENTE: [AROS 200826\\_INFORMEANALISISVARIABLES](#)**

Sin embargo, a la hora de entrenar modelos se ha trabajado con una delta de R218 y otra delta de R280 ya que al haber pérdida de material en la muela así como cambios de muela, es más explicativo. Se calcula haciendo la diferencia entre el valor n y n+1.

#### 4.2.6.2 VARIABLES INFLUYENTES DE CONOS

Variable name	Description	Type
L51	Radial adjustment of the grinding wheel	Control variable
L52	Axial adjustment of the grinding wheel	Control variable
R35	Reference for radial adjustment of the wheel	Factor
R75	Reference for axial adjustment of the wheel	Factor
R322	Wheel diameter	Factor
$T_{i,inv}$	Distance between surfaces of inner and master outer ring	Output

**TABLA 5 VARIABLES Y FACTORES INFLUYENTES PARA LOS MODELOS DE CONOS**

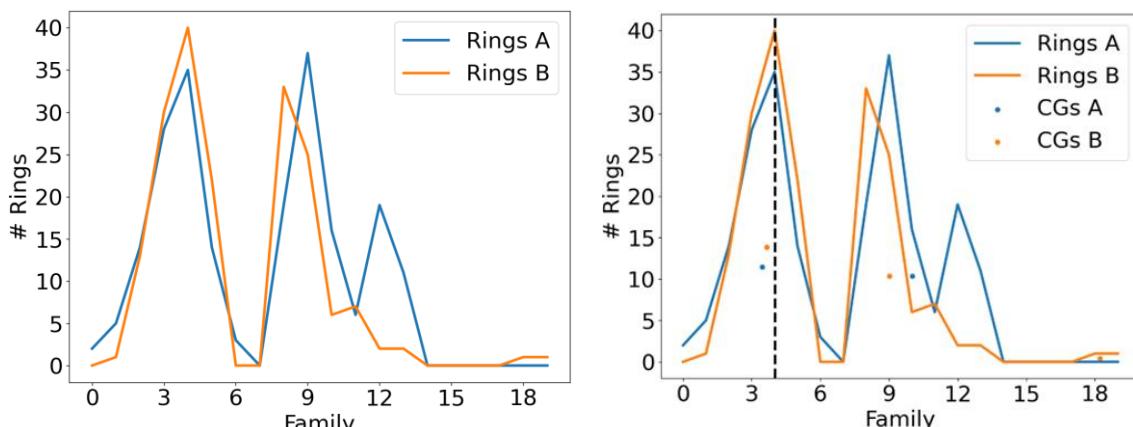
*Archivo fuente: [Conos 200910\\_Patrones\\_fabricacion](#)*

Sin embargo, a la hora de entrenar modelos se ha trabajado con una delta de R322 ya que al haber pérdida de material en la muela así como cambios de muela, es más explicativo. Se calcula también haciendo la diferencia entre el valor n y n+1.

Restablecer las máquinas de rectificado o cambiar sus muelas implica un ajuste manual de las máquinas. Este ajuste produce un cambio notable en las referencias globales de los parámetros. Para entrenar modelos con datos de diferentes muelas y turnos, es necesario realizar una normalización de los datos; es decir, un cambio en su referencia. Esta normalización consiste en utilizar datos incrementales con respecto al último cambio de rueda. De esta manera, las predicciones de los modelos también se realizan en relación con el último cambio de rueda, que es conocido.

#### 4.2.7 MÉTODO DE CENTROS DE GRAVEDAD

El método de cálculo propuesto incluido en el GM se basa en los centros de gravedad de las distribuciones de los anillos interiores (IR) almacenados en la estación de ensamblaje. Este método obtiene las coordenadas del centro de gravedad (CGx, CGy) para cada grupo encontrado en la distribución. La figura de la derecha muestra los centros de gravedad calculados para los 2 grupos encontrados para los anillos interiores del tipo A y para los 3 grupos encontrados para los anillos interiores del tipo B.



**ILUSTRACIÓN 34 (A) DISTRIBUCIÓN TÍPICA DE LOS IR EN LA MÁQUINA DE ENSAMBLAJE. CADA FAMILIA CUBRE UN RANGO DE 4  $\mu\text{m}$ , LO QUE LLEVA A UNA TOLERANCIA DE 80  $\mu\text{m}$ . (B) CENTROS DE GRAVEDAD**

**CALCULADOS PARA CADA GRUPO ENCONTRADO EN LAS DISTRIBUCIONES DE IR (LÍNEAS CONTINUAS)**  
**Y FAMILIA DE OR PROPUESTA BASADA EN LOS CG DE LOS IR (LÍNEA PUNTEADA)**

***Archivo fuente: Mesic correccionesAjustado***

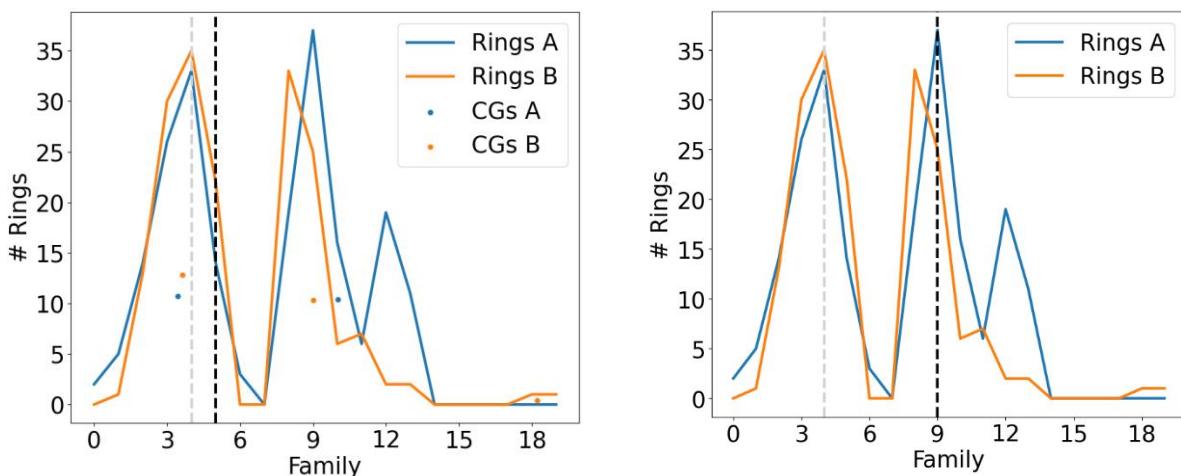
Una vez que se calculan los centros de gravedad para ambas distribuciones de los IR, la familia óptima del anillo exterior (OR) se obtiene de acuerdo con la ecuación siguiente. Esta familia óptima se muestra en la figura de la derecha con una línea discontinua.

$$OR = Round \left[ Min(CG_X^A, CG_X^B) + \Delta CG_X \left( 1 - \frac{Min(A_{max}^A + A_{max}^B)}{A_{max}^A + A_{max}^B} \right) \right]$$

Donde:

- $CG_X^i$  es la coordenada x del centro de gravedad más influyente de la distribución del i-IR.
- $\Delta CG_X$  se obtiene como  $\Delta CG_X = |CG_X^A - CG_X^B|$
- $A_{max}^i$  es el área más grande de los grupos encontrados en la distribución de los anillos interiores i-IR.

El método utilizado para estimar la familia óptima de OR antes de introducir el GM se basaba en la familia de IR con la mayor ocupación. Este método producía una demanda muy fluctuante de OR, lo que, una vez enviado a la máquina de rectificado Lidköping, causaba ajustes de máquina inalcanzables. La siguiente figura muestra la demanda propuesta por ambos métodos para la situación mostrada en la figura anterior después de emparejar algunos IR de la familia 4. En escenarios como este, el nuevo método propuesto supera el enfoque anterior.



**ILUSTRACIÓN 35 CENTROS DE GRAVEDAD Y DISTRIBUCIÓN DE CONOS PROPUESTAS**

***Archivo fuente: Mesic correccionesAjustado***

El gráfico de la izquierda muestra la nueva familia de OR propuesta por el nuevo método después de ensamblar 3 rodamientos. El gráfico de la derecha muestra la familia de OR

propuesta por el método anterior. En líneas grises y negras discontinuas, se muestra la familia propuesta en la situación de la primera figura y después de emparejar 3 rodamientos, respectivamente. El método anterior presenta una alta variabilidad.

## 4.2.8 RECOPILACIÓN DE DATOS

### 4.2.8.1 INDICADORES DE BUENA APROXIMACIÓN

A la hora de escoger el método que mejor se aproxima a la realidad se tienen en cuenta dos parámetros:

Error de raíz cuadrada media (RMSE) es la desviación estándar de los valores residuales (errores de predicción). Los valores residuales son una medida de la distancia de los puntos de datos de la línea de regresión; RMSE es una medida de cuál es el nivel de dispersión de estos valores residuales. En otras palabras, indica el nivel de concentración de los datos en la línea de mejor ajuste. Entonces cuanto más pequeño es este error mejor se aproxima el modelo a la realidad.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}}$$

$\hat{y}_i$  : valores estimados

$y_i$ : valores observados

n: número de observaciones

El coeficiente de determinación es una medida utilizada para explicar cuánta variabilidad de un factor puede ser causada por su relación con otro factor relacionado. Esta correlación se representa como un valor entre 0,0 y 1,0. Un valor de 1,0 indica un ajuste perfecto y, por tanto, un modelo muy fiable para las previsiones futuras, mientras que un valor de 0,0 indicaría que el cálculo no logra modelar los datos con precisión en absoluto.

$$R^2 = \frac{\sum_{t=1}^T (\hat{Y}_t - \bar{Y})^2}{\sum_{t=1}^T (Y_t - \bar{Y})^2}$$

$\hat{Y}_t$ : estimación del modelo

$\bar{Y}$ : media

$Y_t$ : valor real

### 4.2.8.2 MODELOS DE LA LÍNEA Y TRATAMIENTO DE DATOS

Las máquinas de rectificado de anillos interiores y exteriores son el núcleo del GM. Estas estaciones se han estado modelando con algoritmos de aprendizaje automático

basados en la regresión de procesos gaussianos (GPR) con un núcleo exponencial. Aunque ambos modelos se basan en algoritmos similares, tienen diferentes entradas, salidas y propósitos, que se describen brevemente en las siguientes subsecciones.

#### **4.2.8.2.1 MODELO DE LA MÁQUINA DE RECTIFICADO DE AROS**

Este modelo predice la configuración adecuada de la máquina para obtener el anillo exterior óptimo (OR), considerado como aquel que será emparejado directamente cuando llegue a la estación de ensamblaje. Las características de este modelo (es decir, las variables de entrada para el entrenamiento) son el estado de la máquina, compuesto por variables independientes con un alto impacto sobre la dimensión crítica (Te) del OR, y el valor deseado de la dimensión crítica en sí, calculado a partir de las distribuciones de los anillos interiores (IR) y sus centros de gravedad como se detalla en la sección anterior.

Las características utilizadas para entrenar el modelo están principalmente relacionadas con el ajuste de la posición relativa entre la rueda de rectificado y el OR, y deben ser preprocesadas antes de entrenar el modelo. Los principales procesos son un filtrado de ruido y una estandarización para reducir la alta variabilidad producida por los cambios de la rueda y otras alteraciones en la estación.

#### **4.2.8.2.2 MODELO DE LA MÁQUINA DE RECTIFICADO DE CONOS**

Este modelo predice la dimensión crítica de los anillos interiores rectificados ( $T_{i,inv}$ ), y sus características están relacionadas con el perfil de la rueda de rectificado y la posición relativa entre la rueda de rectificado y el IR. Predecir la dimensión crítica de los anillos durante el proceso de rectificado permite estimar la distribución que se encontrará en la estación de ensamblaje después de aproximadamente 1.5 horas, que es el tiempo que tardan los anillos IR rectificados en llegar a la estación de ensamblaje. Tener información sobre el estado futuro de la estación de ensamblaje permite que la máquina de rectificado de OR comience a trabajar antes de que los IR se clasifiquen en la estación de emparejamiento. El preprocesamiento de datos no es tan exhaustivo como en el caso del OR, ya que el régimen de producción en esta estación es mucho más estable y las ruedas de rectificado se cambian cada 15,000 procesos en comparación con los 600 procesos para la estación de rectificado de OR.

#### **4.2.8.2.3 REENTRENAMIENTO DE LOS MODELOS**

Durante la validación de los modelos, se detecta un sesgo que aumenta con el número de procesos de rectificado en las predicciones del modelo. Este sesgo es causado principalmente por cambios en las referencias globales de aquellas características utilizadas para entrenar los modelos y que están relacionadas con la posición relativa entre la rueda de rectificado y el anillo.

Las principales razones de los cambios en las referencias globales son, en primer lugar, las interrupciones en la producción que conllevan un reajuste manual de la máquina de

rectificado, como los cambios de la rueda de rectificado cuando se desgasta, paradas de mantenimiento y reparaciones, y en segundo lugar, los propios procesos de rectificado, que causan el desgaste de los componentes de la estación y vibraciones que afectan a las referencias globales.

El sesgo causado por los cambios de la rueda de rectificado, que es la causa más frecuente y con mayor impacto. Para reducir el impacto negativo en los modelos, se realiza un preprocesamiento de datos que consiste en normalización y estandarización. En este caso, la normalización se entiende como el uso de datos incrementales con respecto al último cambio de la rueda y la estandarización como la búsqueda de una referencia adecuada después de cada cambio de rueda para la mencionada normalización.

Más adelante se observará que para que las predicciones de los modelos sean buenas hay que reentrenarlos periódicamente para que no pierdan precisión y que generalicen bien metiendo datos de entrada desconocidos.

#### **4.2.8.3 ESTRUCTURA DE DATOS**

Los módulos detallados están diseñados para interactuar, compartir información, trabajar juntos y, en última instancia, formar el Gémeo Digital (GM). Están diseñados y desarrollados de manera modular y por separado para darle al GM la flexibilidad suficiente para probar y simular tantos cambios en la línea y en el GM como sea posible. Por ejemplo, se podría implementar un nuevo enfoque para calcular la familia óptima de anillos exteriores (OR) simplemente cambiando el módulo de los centros de gravedad (CGs), mientras que una nueva estrategia de reentrenamiento podría probarse modificando solo los modelos de ML.

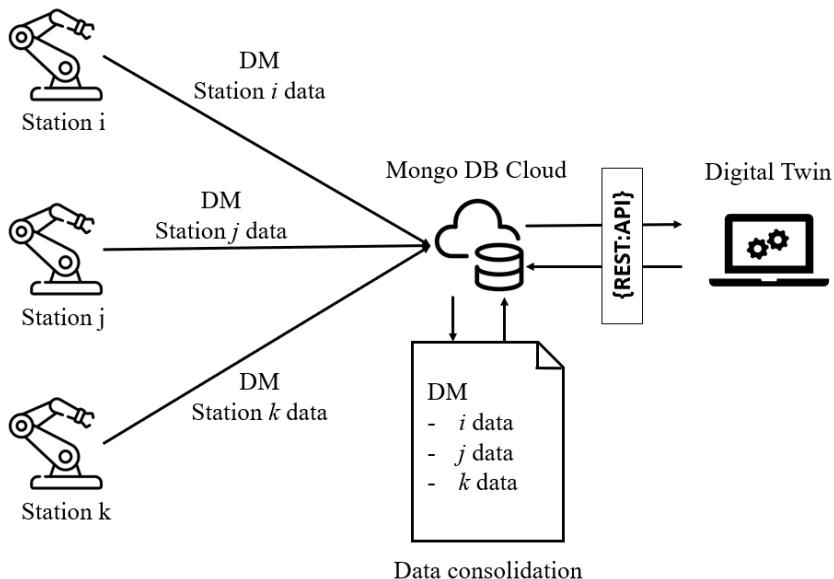
Los módulos tratados en las secciones anteriores no son los únicos elementos del GM. Se necesita una base de datos robusta y lo suficientemente accesible conectada a la línea (IoT), así como una infraestructura adecuada para alojar el propio GM.

##### **4.2.8.3.1 BASES DE DATOS Y COMUNICACIÓN DEL GEMELO DIGITAL**

La base de datos elegida es una instancia de MongoDB en la nube, donde se almacena la información de las diferentes estaciones en cuanto se genera en los PLCs. Los datos se envían desde los PLCs a la base de datos utilizando protocolos que dependen de la compatibilidad de la máquina. Es en la propia base de datos donde los datos de las diferentes estaciones se consolidan en torno al datamatrix (DM) correspondiente, que es un identificador único de componente impreso al comienzo de la línea en cada anillo y leído en cada estación para asociar la información al DM. De esta manera, cada DM (es decir, anillo interior o anillo exterior) se asocia con los datos de cada estación a medida que avanza por la línea de producción.

La ilustración 36 muestra esquemáticamente cómo fluye la información desde las estaciones de la línea hasta la base de datos en la nube. El GM se comunica con la

nube de MongoDB y, por tanto, con la línea de producción a través de una API. Esto significa que el GM está contenido en una API REST que se llama desde la base de datos cada vez que ocurre un evento relacionado en la línea. Los eventos que activan una llamada a la API, que se detallan en la siguiente sección, son: el rectificado de los anillos interiores y exteriores, la recepción de los anillos en la máquina de emparejamiento, el ensamblaje de los rodamientos y cualquier rechazo en los controles de calidad.



**ILUSTRACIÓN 36 ESQUEMA DE COMUNICACIÓN Y FLUJO DE DATOS DESDE LA LÍNEA DE PRODUCCIÓN HASTA EL GEMELO DIGITAL (GD)**

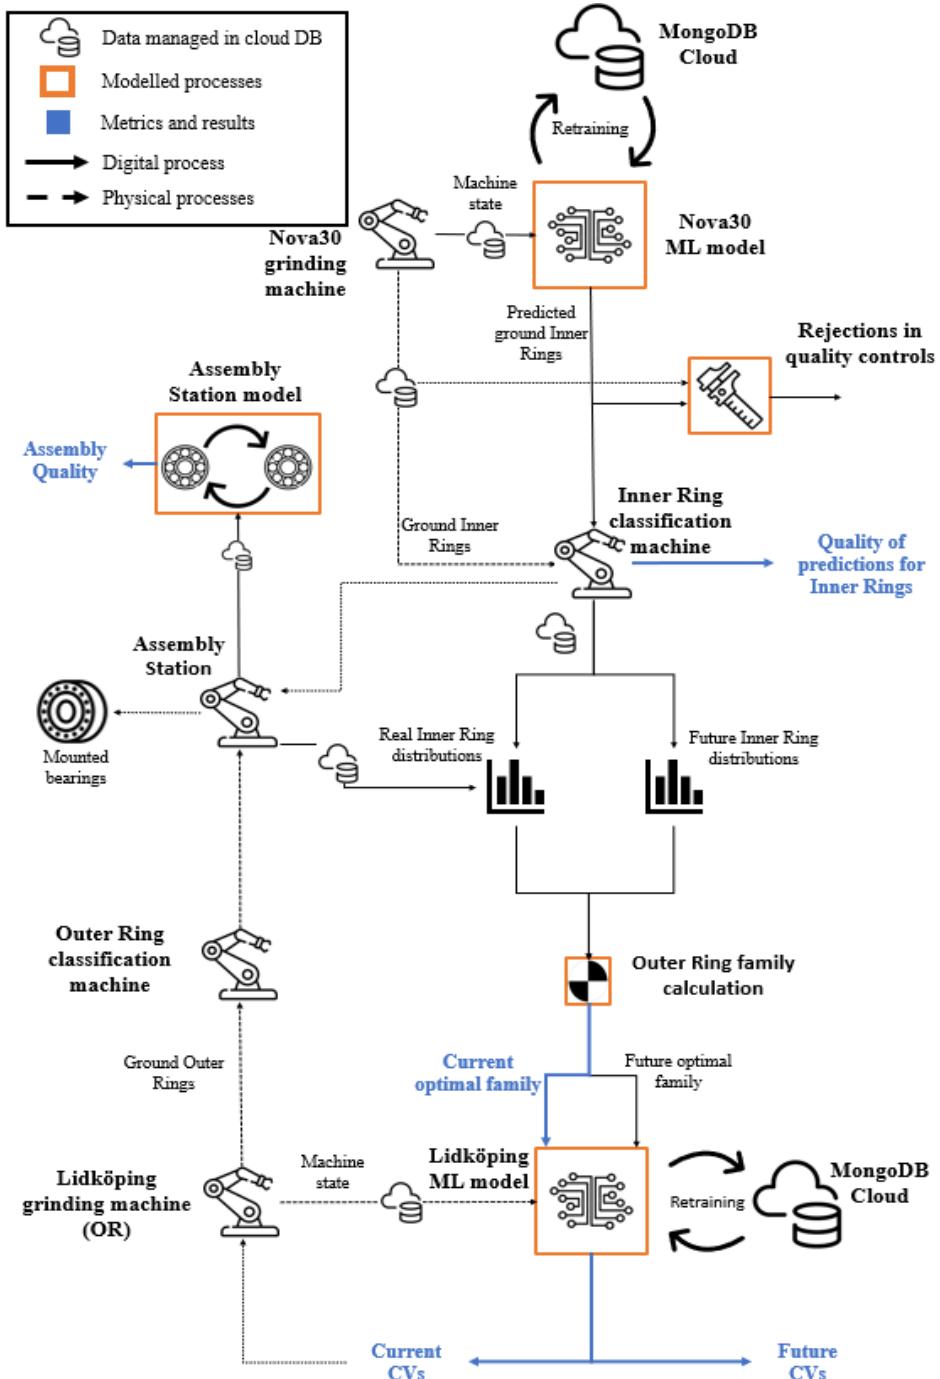
*Archivo Fuente: [Mesic correccionesAjustado](#)*

#### 4.2.8.3.2 INTEGRACIÓN Y OPERACIÓN GENERAL DEL GEMELO DIGITAL

La enumeración de eventos anterior se utiliza como referencia para abordar la operación global del Gemelo Digital (GM), la cual también se representa en la ilustración 37. Cada vez que un anillo interior (IR) llega a la máquina de rectificado Nova30, los datos del proceso de rectificado se cargan en la base de datos y se activa el GM. Este evento envía el estado de la máquina al modelo de ML de Nova30 y predice la dimensión crítica del IR. La dimensión crítica real de este anillo se medirá al menos 1.5 horas después, cuando llegue a la máquina de emparejamiento. Sin embargo, las predicciones permiten estimar de antemano las distribuciones de los IR que se encontrarán en la estación de ensamblaje.

Al tener las distribuciones futuras de los IR actualizadas, también se activa el cálculo del OR óptimo para estas distribuciones utilizando el método de los CGs. Una vez que se calcula el OR óptimo futuro, esta información puede enviarse junto con el estado actual de la máquina de rectificado Lidköping a su modelo de ML. El modelo generará la configuración de la máquina (variables de control futuras CVs en la ilustración 37 para cumplir con este requisito futuro).

A medida que los IR se reciben en la estación de clasificación, se mide su dimensión crítica real, por lo que también se puede calcular el error de predicción del modelo Nova30 como indicador de la calidad de las predicciones. Después de clasificar el IR en grupos según su dimensión crítica,  $T_i,inv$ , se actualizan las distribuciones actuales, lo que activa al mismo tiempo el cálculo del OR óptimo (método de los CGs). Esta familia óptima y el estado actual de la máquina Lidköping se envían a su modelo de ML para estimar la configuración actual requerida de la máquina.



**ILUSTRACIÓN 37 ARQUITECTURA GLOBAL DEL GEMELO DIGITAL (GD) Y SU INTEGRACIÓN EN LA LÍNEA DE PRODUCCIÓN. EN LÍNEAS PUNTEADAS Y CONTINUAS SE REPRESENTAN LOS PROCESOS FÍSICOS Y DIGITALES, RESPECTIVAMENTE. RESULTADOS EN AZUL. ESTACIONES Y PROCESOS PRINCIPALES MODELADOS EN NARANJA.**

**Archivo Fuente: Mesic correccionesAjustado**

En líneas discontinuas y continuas se representan los procesos físicos y digitales, respectivamente. Resultados en azul. Principales estaciones y procesos modelados en naranja

A medida que los anillos exteriores (OR) se reciben en la máquina de rectificado Lidköping, se activa su modelo de ML para predecir su dimensión crítica,  $T_e$ . Aunque estas predicciones no se utilizan explícitamente en el GM, se emplean para calcular la precisión del modelo como un control de calidad interno.

Además, cada nuevo dato recibido de esta estación actualiza el estado de la máquina, que se almacena internamente en el GM y se usa como entrada cada vez que se ejecuta el ML.

La recepción de los OR en la estación de ensamblaje produce una actualización de la distribución actual de los OR y activa el módulo de ensamblaje, que simula los emparejamientos según las estrategias implementadas en el GM. Incluir el proceso de emparejamiento como un módulo independiente permite replicar el comportamiento real de la línea o simular otros métodos de emparejamiento. La calidad del emparejamiento calculada en este momento puede diferir de la realidad al probar nuevas estrategias de emparejamiento.

Cada ensamblaje de un rodamiento en la estación de ensamblaje produce una actualización tanto de las distribuciones actuales como futuras de los anillos. Estas modificaciones activan el cálculo del OR óptimo para las situaciones actual y futura, y por lo tanto el modelo de ML de Lidköping para estimar la configuración necesaria de la máquina en ambos escenarios. Una vez que se monta un rodamiento, también se mide la calidad real del ensamblaje y se guarda como un resultado. Esta calidad de emparejamiento es la misma que la obtenida del módulo de emparejamiento cuando la estrategia implementada en el módulo de emparejamiento de la siguiente tabla es la misma que en la estación de emparejamiento.

Método de emparejamiento	Aro grupo,i	Cono A grupo,j	Cono B grupo,k
Recto	$i$	$j = i$	$k = i$
V	$i$	$\{i + j   (j \in \mathbb{Z})[-3 \leq j \leq 3, j + k = 0]\}$	$j + k = 0$
L	$i$	$\{i + j   (j \in \mathbb{Z})[-2 \leq j \leq 2,  j + k  \leq 2]\}$	$k = i$

**TABLA 6 REPRESENTACIÓN DE LAS ESTRATEGIAS DE EMPAREJAMIENTO UTILIZADAS PARA MODELAR LA ESTACIÓN DE ENSAMBLAJE.**

**Archivo Fuente: Mesic correccionesAjustado**

Cualquier rechazo en las estaciones de control de calidad también es considerado por el GM. Si un IR es rechazado en una estación ubicada entre la máquina de rectificado Nova30 y la estación de ensamblaje, las distribuciones futuras de los IR se actualizarán,

lo que activará el cálculo de una nueva familia óptima de OR y el ML de Lidköping para proponer una nueva configuración de la máquina.

## 5. DISEÑO Y DESARROLLO DEL GEMELO DIGITAL

En esta sección se procede a desarrollar el gemelo digital. Se realizan desde pruebas sencillas para ver cómo se comportan los datos ( uso de datos sintéticos ) frente a ciertos factores como el ruido y las variables espurias hasta simulaciones con datos reales de los aros y de los conos para estudiar la mejor manera de desarrollar el modelo que se implementará en el gemelo digital. Finalmente, se analiza el gemelo digital desarrollado con datos antiguos y con datos y mejoras nuevos.

### 5.1 PRUEBAS CON DATOS SINTÉTICOS

En este apartado se hacen pruebas sobre datos sintéticos de temperaturas para ver el comportamiento de modelos con y sin variables con influencia mínima y con ruido (variación o componente no deseado) ya que es algo que puede ocurrir en la toma de datos de máquinas expuestas a todo tipo de perturbaciones como vibraciones, ondas, etc.

#### 5.1.1 ENTRENAMIENTO SIN RUIDO Y SIN VARIABLES ESPUREAS

Primero se procede a entrenar los modelos con los datos sintéticos en cuestión. En este caso se entrena con datos sin ruido ( factor de ruido 0 ) y sin variables espurias, por lo que únicamente se trabaja con las variables más influyentes. En la figura siguiente se observa que el mejor modelo de entrenamiento es la regresión lineal ya que tiene el menor RMSE y un  $R^2 = 1$  por lo tanto los datos reales se ajustan muy bien a las predicciones.

1 Tree	RMSE (Validation): 0.00016185
Last change: Fine Tree	2/2 features
2.1 Linear Regression	RMSE (Validation): 5.2128e-09
Last change: Linear	2/2 features
2.2 Linear Regression	RMSE (Validation): 2.1066e-13
Last change: Interactions Linear	2/2 features
2.3 Linear Regression	RMSE (Validation): 5.2147e-09
Last change: Robust Linear	2/2 features
2.4 Stepwise Linear Regression	RMSE (Validation): 5.2128e-09
Last change: Stepwise Linear	2/2 features
2.5 Tree	RMSE (Validation): 0.00016185
Last change: Fine Tree	2/2 features

**Model 2.2: Linear Regression**  
Status: Trained

**Training Results**

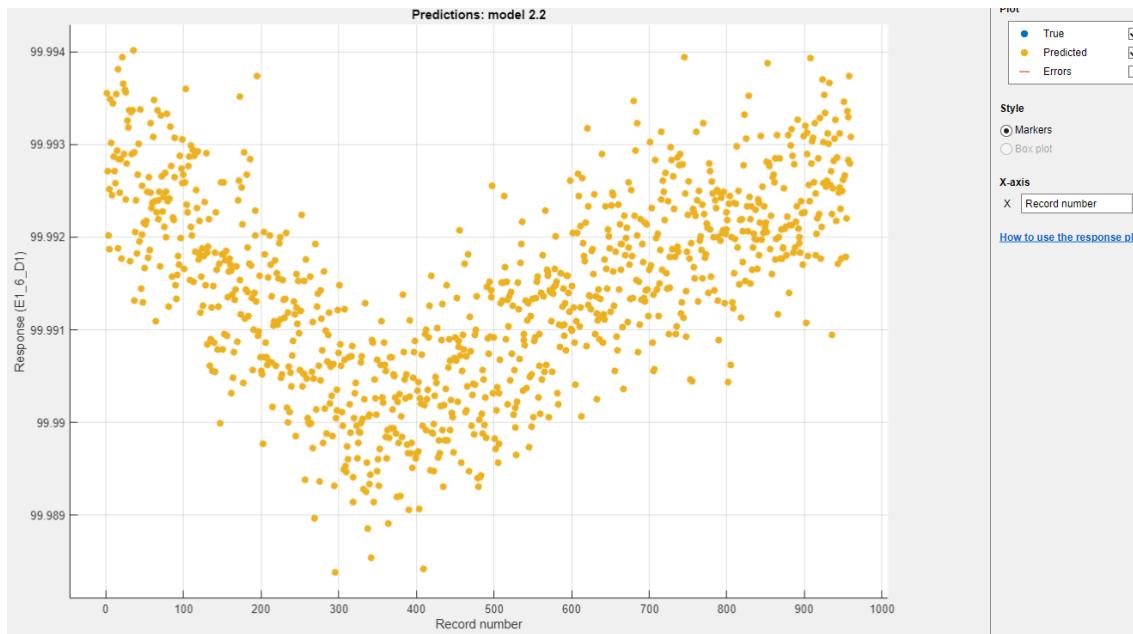
RMSE (Validation)	2.1066e-13
R-Squared (Validation)	1.00
MSE (Validation)	4.4376e-26
MAE (Validation)	1.4720e-13
MAPE (Validation)	0.0%
Prediction speed	~5100 obs/sec
Training time	13.25 sec
Model size (Compact)	~5 kB

**Model Hyperparameters**

- Feature Selection: 2/2 individual features selected
- PCA: Disabled
- Optimizer: Not applicable

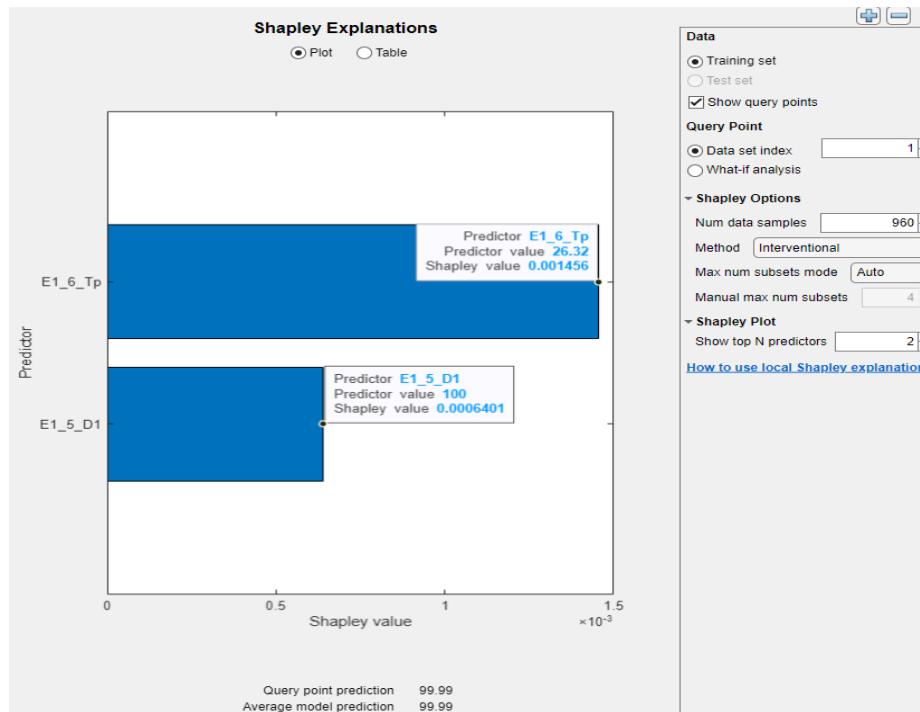
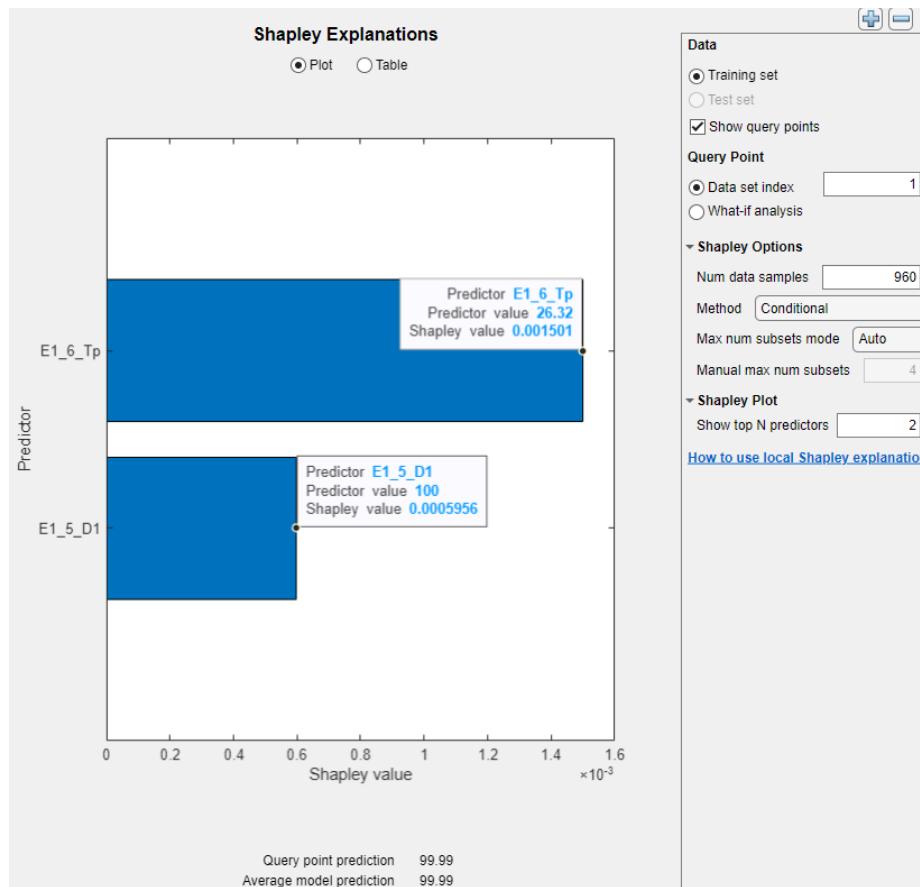
**TABLA 7 MODELOS PARA EL ENTRENAMIENTO CON DATOS SINTÉTICOS**

El buen ajuste de los datos reales y de las predicciones se pueden observar en la siguiente gráfica. Los puntos correspondientes a cada uno de estos datos se superponen.



**ILUSTRACIÓN 38 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICCIONES**

Más adelante se usan las herramientas de explain para ver como las variables explican el modelo. Se hace, por un lado, un análisis de como estas variables afectan al modelo sin tener en cuenta las interacciones entre ellas de manera independiente y después teniendo en cuenta las interacciones entre ellas.

**ILUSTRACIÓN 39 ANÁLISIS INTERVENCIONAL SIN INTERACCIONES ENTRE VARIABLES****ILUSTRACIÓN 40 ANÁLISIS CONDICIONAL CON INTERACCIONES ENTRE VARIABLES**

Como podemos observar el entrenamiento sin ruido ni variables espurias tiene un residuo RMSE muy bajo por lo tanto las predicciones que se han hecho durante este entrenamiento son muy buenas (RMSE próximo a 0 y R2 =1). Gráficamente los puntos correspondientes de las predicciones coinciden con los puntos correspondientes a lo que pasa en realidad. Analizando como influyen las variables en la variable de salida así como la dependencia entre ellas observamos que la temperatura de la pieza (Tp) influye positivamente aumentando el valor de la salida y que E1\_5\_D1 ( diámetro de la pieza antes de llegar a la estación final ) también lo hace pero en menor medida. Teniendo después en cuenta en la última gráfica la dependencia de las variables entre sí, el comportamiento es el mismo.

### 5.1.2 ENTRENAMIENTO CON VARIABLES ESPURIAS

Como podemos observar en el [\*ANEXO 2 DATOS SINTETICOS → ENTRENAMIENTO CON VARIABLES ESPURIAS\*](#) el entrenamiento sin ruido y con variables espurias tiene un residuo RMSE muy bajo también pero más alto que en el caso anterior, por lo tanto las predicciones que se han hecho durante este entrenamiento siguen siendo muy buenas (RMSE próximo a 0 y R2 =1). Gráficamente los puntos correspondientes de las predicciones coinciden con los puntos correspondientes a lo que pasa en realidad. Analizando como influyen las variables en la variable de salida así como la dependencia entre ellas observamos según la penúltima gráfica que no tiene en cuenta la dependencia entre variables, que la temperatura de la pieza (Tp) influye positivamente aumentando el valor de la salida y que E1\_5\_D1 también lo hace pero en menor medida, al igual que en el primer caso sin variables espurias. Teniendo después en cuenta en la última gráfica la dependencia de las variables entre sí, el comportamiento varía al introducir esta condición de variables espurias. Se observa que las variables que más influyen siguen siendo Tp y E1\_5\_D1, sin embargo ahora el resto de las variables también influyen.

### 5.1.3 ENTRENAMIENTO SOLO CON RUIDO

Como podemos observar en el [\*ANEXO 2 DATOS SINTETICOS → FACTOR RUIDO \(SOLO CON RUIDO\)\*](#) el entrenamiento con factor de ruido de 3,8 tiene un residuo RMSE mucho más alto que en los casos anteriores, sin embargo sigue teniendo un valor bastante bajo. El R2 sigue siendo próximo a 1 pero ha disminuido ligeramente. Gráficamente los puntos correspondientes de las predicciones ya no coinciden con los puntos correspondientes a lo que pasa en realidad, lo que indica que la aproximación ha empeorado. Analizando como influyen las variables en la variable de salida así como la dependencia entre ellas observamos que la temperatura de la pieza (Tp) influye positivamente aumentando el valor de la salida y que E1\_5\_D1 esta vez lo hace negativamente reduciendo el valor del output pero en menor medida. Teniendo después en cuenta en la última gráfica la dependencia de las variables entre sí el comportamiento es el mismo que en la penúltima gráfica.

### 5.1.4 ENTRENAMIENTO CON RUIDO Y VARIABLES ESPURIAS

Como podemos observar en el *ANEXO 2 DATOS SINTETICOS → FACTOR RUIDO (CON RUIDO Y VARIABLES ESPURIAS)* el entrenamiento con ruido y con variables espurias tiene un residuo RMSE ligeramente más bajo que en el caso anterior pero prácticamente igual y el R2 también se ha mantenido. Gráficamente los puntos correspondientes de las predicciones tampoco coinciden exactamente con los puntos correspondientes a lo que pasa en realidad. Analizando como influyen las variables en la variable de salida así como la dependencia entre ellas observamos que la temperatura de la pieza (Tp) influye positivamente aumentando el valor de la salida y que E1\_5\_D1 también lo hace pero en menor medida. El resto de las variables prácticamente no tienen fuerza en la influencia sobre el output. Teniendo después en cuenta en la última gráfica la dependencia de las variables entre sí hay un cambio notable, las variables que antes casi no tenían influencia ahora sí que la tienen y la temperatura ambiente Ta ahora influye más que E1\_5\_D1 que era la segunda que más influía hasta ahora.

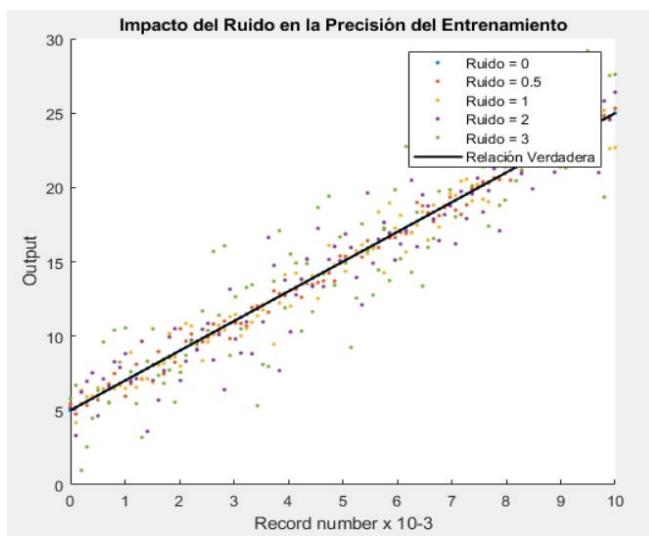
### 5.1.5 OBSERVACIONES DE PRUEBAS CON DATOS SINTÉTICOS

Las pruebas realizadas muestran que en general el modelo que hace mejores predicciones es la regresión lineal. Vemos que a mayor ruido, peores predicciones ya que hace que el RMSE aumente y que el R2 baje. Además el ruido hace que en el shapley haya errores a la hora de mostrar la influencia de las variables de entrada en el output ya que al variar el factor de ruido los comportamientos de estas variables cambian. Al meter variables espurias el error aumenta ligeramente y permite ver la influencia de estas últimas en el resultado final. Sin embargo, por lo general influyen bastante menos que las dos variables más importantes (Tp y E1\_5\_D1) y por lo tanto a pesar de añadirlas al modelo para que sea más real y explicativo se pueden despreciar para ahorrar el coste computacional en la mayoría de los casos. La precisión que aportan suele ser mínima. La siguiente tabla sintetiza lo obtenido:

Entrenamiento	Factor de ruido	RMSE	R <sup>2</sup>	validación
Sin ruido y variables espurias	-	2,1066E-13	1	Muy bueno
Con variables espurias	-	2,2645E-13	1	Muy bueno
Solo ruido	3,8	0,00010855	0,99	Bueno
	4,7	0,00013412	0,98	Bueno
	7,5	0,00021447	0,96	Bueno
Ruido y variables espurias	3,8	0,00010526	0,99	Bueno
	4,7	0,00013684	0,98	Bueno
	7,5	0,00021447	0,96	Bueno

**TABLA 8 RESUMEN DE RESULTADOS OBTENIDOS ENTRENANDO CON DATOS SINTÉTICOS**

Además mediante Matlab se ha procedido a graficar esta influencia negativa del ruido en las predicciones del modelo con otros factores de ruido:



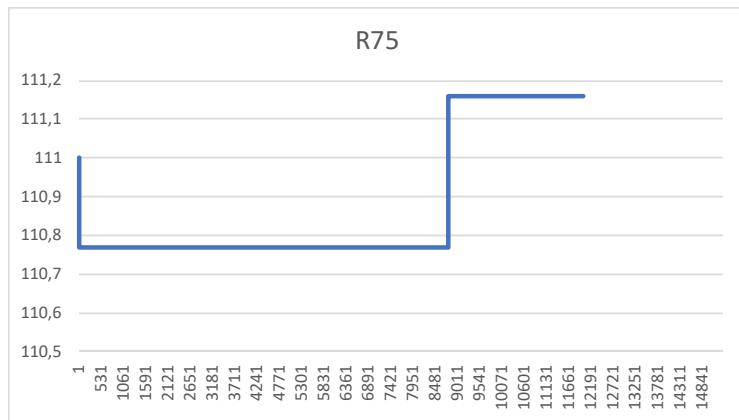
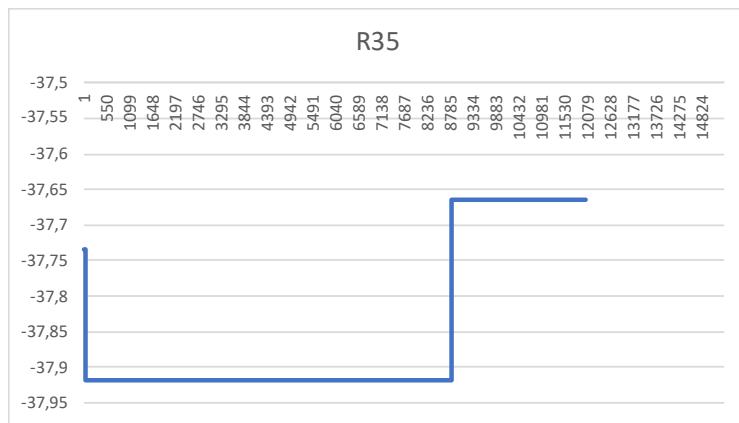
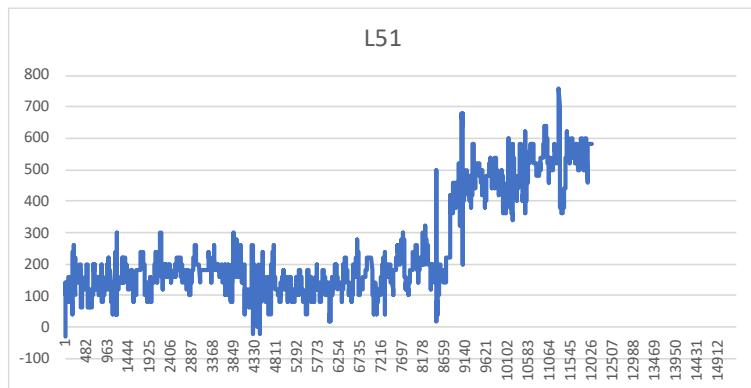
**ILUSTRACIÓN 41 GRÁFICA MOSTRANDO LA INFLUENCIA DEL RUIDO**

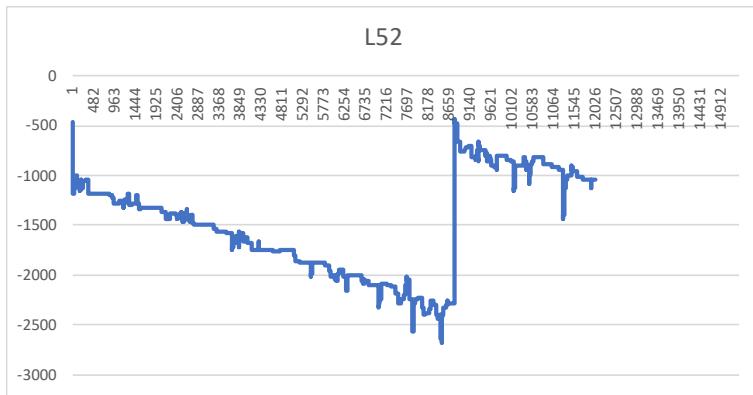
## 5.2 CONOS

En este apartado se realiza un análisis previo de las variables que intervienen en los modelos de los conos. Se entrenan los modelos cambiando ciertos parámetros como la frecuencia de entrenamiento.

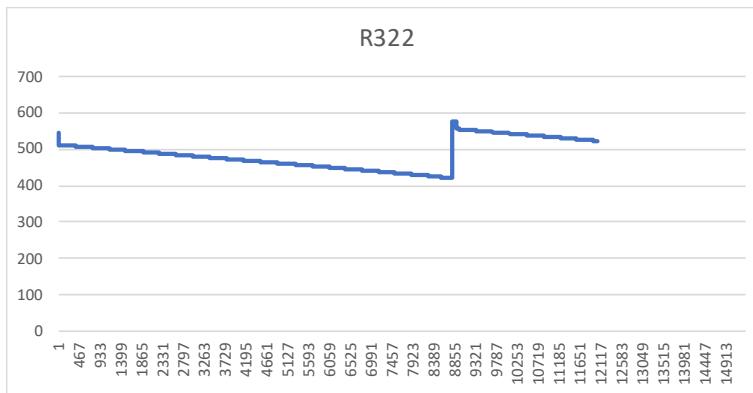
### 5.2.1 ANÁLISIS PREVIO DE VARIABLES DE CONOS

Se plantea gráficamente el comportamiento de las 5 variables influyentes en conos A (se procede de la misma manera para los conos B en el [ANEXO 3 CONOS→ CONOS B](#)):

**CONOS A****ILUSTRACIÓN 42 GRÁFICA DEL COMPORTAMIENTO DE LA POSICIÓN FIN DE TRABAJO Z****ILUSTRACIÓN 43 GRÁFICA DEL COMPORTAMIENTO DE LA POSICIÓN FIN DE TRABAJO X****ILUSTRACIÓN 44 GRÁFICA DEL COMPORTAMIENTO DE LA SUMA DE CORRECCIONES EJE X**



**ILUSTRACIÓN 45 GRÁFICA DEL COMPORTAMIENTO DE LA SUMA DE CORRECCIONES EJE Z**



**ILUSTRACIÓN 46 GRÁFICA DEL COMPORTAMIENTO DEL DIÁMETRO ACTUAL DE MUELA**

Todas estas variables presentan un comportamiento estable o repetitivo en forma de patrones. La variable R322 muestra una distribución de diente de sierra. El tramo en el que el valor de la variable crece o decrece rápidamente corresponde con un cambio de muela. En este caso la muela de conos aguanta muchos más rectificados que la de aros como se verá más adelante. Se entrenará el modelo teniendo en cuenta una delta de R322 (valores iniciales menos los finales) para ver el decremento de valores de esta variable y así detectar más fácilmente el cambio de muela. Sin embargo, como se observará no se hacen entrenos y testeos por muela en este caso, ya que solo hay un cambio de muela en estos datos proporcionados por lo que no tiene mucho sentido.

## 5.2.2 ENTRENAMIENTOS Y TESTEOS DE CONOS

En esta sección se va a ver cuál es el mejor modelo de entrenamiento de los conos así como la mejor manera de entrenar y de testear variando lo siguiente:

### 5.2.2.1 ENTRENO TODO CONO A Y TEST TODO CONO B

En este caso se entrena todos los datos del mes del cono A y se realizan los test de los datos de todo el mes de los conos B. Podemos ver que aquí el modelo seleccionado es el exponencial gaussiano ya que además de tener el RMSE más bajo y el  $R^2$  más próximo a 1 en el entrenamiento, también proporciona los mejores resultados en el test.

**Model 3.4: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.0078305
R-Squared (Validation)	0.70
MSE (Validation)	6.1316e-05
MAE (Validation)	0.0051769
MAPE (Validation)	824.0%
Prediction speed	~4200 obs/sec
Training time	59975 sec
Model size (Compact)	~573 kB

**Test Results**

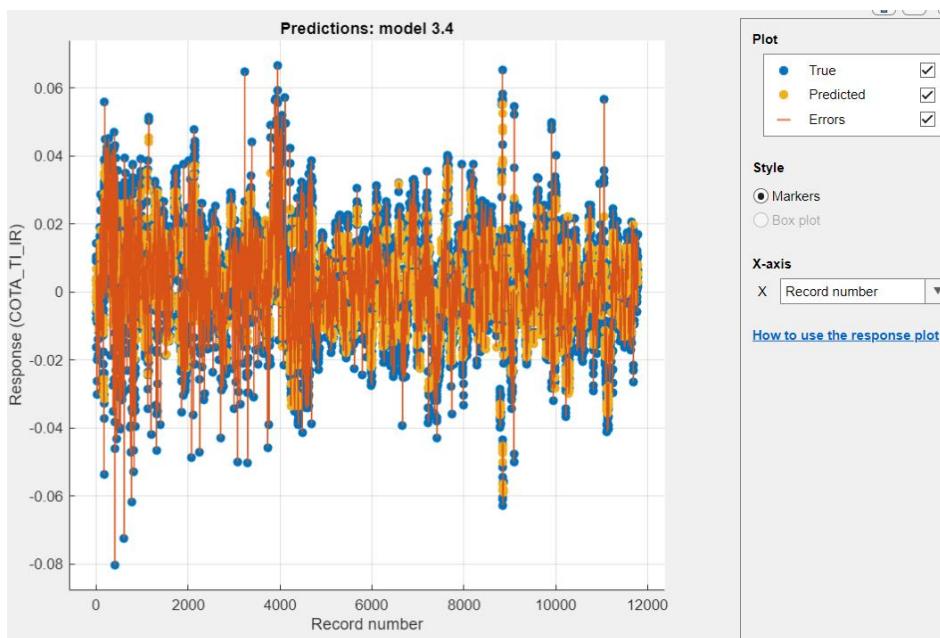
RMSE (Test)	0.0088865
R-Squared (Test)	0.63
MSE (Test)	7.8969e-05
MAE (Test)	0.0066199
MAPE (Test)	233.7%

▶ Model Hyperparameters  
 ▶ Feature Selection: 5/5 individual features selected  
 ▶ PCA: Disabled  
 ▶ Optimizer: Not applicable

<b>2.21</b> Gaussian Process Regression	RMSE (Test): Canceled
Last change: Rational Quadratic GPR	5/5 features
<b>2.22</b> Neural Network	RMSE (Test): 0.86031
Last change: Narrow Neural Network	5/5 features
<b>2.23</b> Neural Network	RMSE (Test): 0.48953
Last change: Medium Neural Network	5/5 features
<b>2.24</b> Neural Network	RMSE (Test): 1.3698
Last change: Wide Neural Network	5/5 features
<b>2.25</b> Neural Network	RMSE (Test): 0.031367
Last change: Bilayered Neural Network	5/5 features
<b>2.26</b> Neural Network	RMSE (Test): 0.66443
Last change: Trilayered Neural Network	5/5 features
<b>2.27</b> Kernel	RMSE (Test): 0.010344
Last change: SVM Kernel	5/5 features
<b>2.28</b> Kernel	RMSE (Test): 0.010279
Last change: Least Squares Regression Kernel	5/5 features
<b>3.1</b> Gaussian Process Regression	RMSE (Test): 0.0088940
Last change: Rational Quadratic GPR	5/5 features
<b>3.2</b> Gaussian Process Regression	RMSE (Test): 0.0093870
Last change: Squared Exponential GPR	5/5 features
<b>3.3</b> Gaussian Process Regression	RMSE (Test): 0.0091355
Last change: Matern 5/2 GPR	5/5 features
<b>3.4</b> Gaussian Process Regression	RMSE (Test): <b>0.0088865</b>
Last change: Exponential GPR	5/5 features

**TABLA 9 MODELOS DE ENTRENAMIENTO DE LOS CONOS**

En los resultados del test se aprecia un buen resultado con un RMSE bajo y un  $R^2$  de 0,63 (mejorable pero asequible).

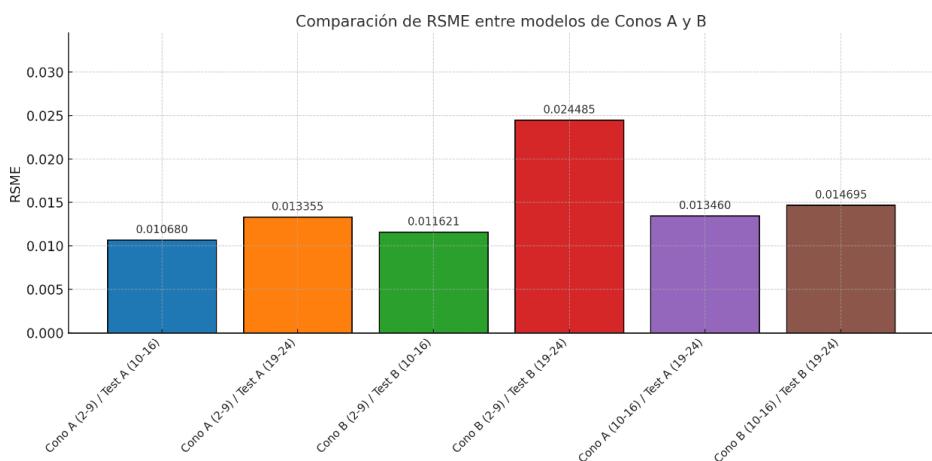


**ILUSTRACIÓN 47 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

En la gráfica se observa que a pesar de ser una buena aproximación las predicciones presentan errores.

#### 5.2.2.2 ENTRENO DÍA 2 AL 9 Y TEST DEL 10 AL 16 CONO A (ENTRENO SEMANAL)

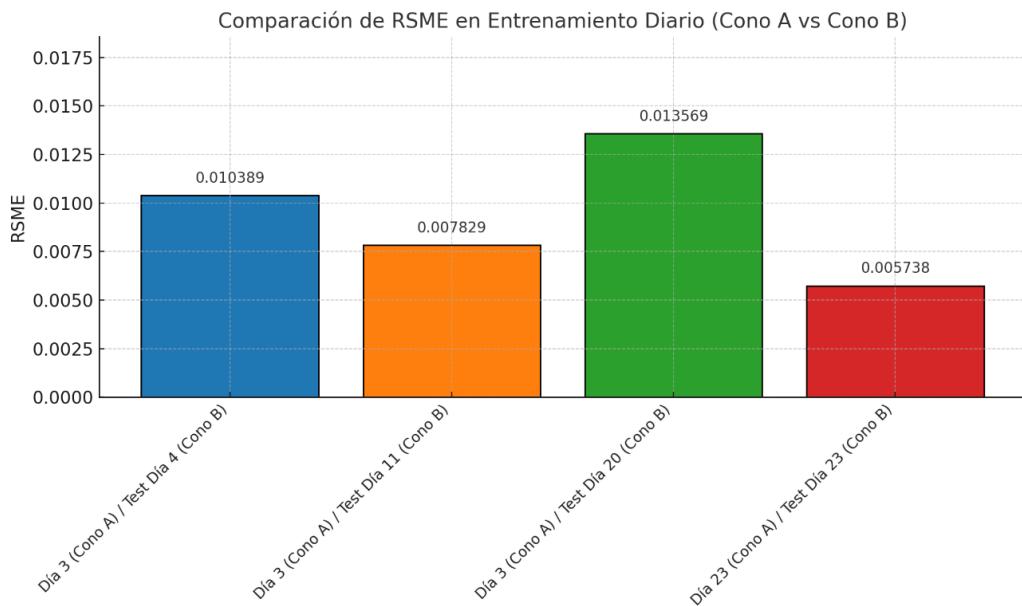
Este es un ejemplo de entrenamiento semanal, los resultados obtenidos de este intervalo de días así como los demás, se encuentran en el [ANEXO 3 CONOS → ENTRENAMIENTO Y TEST POR SEMANAS](#) ya sea con datos de un mismo cono o con datos semanales de diferentes conos (A o B). Teniendo todas las pruebas semanales que se han realizado, si lo comparamos con el caso mensual anterior los resultados son peores ya que el RMSE es más alto y los R2 tienden menos a 1.



**ILUSTRACIÓN 48 RESUMEN COMPARATIVO DE ENTRENAMIENTOS Y TEST SEMANALES**

### 5.2.2.3 ENTRENO CONO A DÍA 23 Y TEST CONO B DÍA 23 (ENTRENO DIARIO)

Se obtiene un RMSE muy bajo y por tanto muy bueno y un R<sup>2</sup> de 0,77 por lo tanto mejor que en los casos anteriores ya que se aproxima más a 1. Ver las pruebas realizadas en el [ANEXO 3 CONOS → ENTRENAMIENTO Y TEST POR DIAS](#).



#### ILUSTRACIÓN 49 RESUMEN COMPARATIVO DE ENTRENAMIENTOS Y TEST DIARIOS

### 5.2.2.4 OBSERVACIONES DE LOS CONOS

Comparando todas las pruebas de este apartado y las presentes en los correspondientes anexos, se observa que el método de entrenamiento con un RMSE más bajo y con mejor R<sup>2</sup> es el de entrenar diariamente un cono A y testear el cono B durante ese mismo día. Al tener un RMSE más bajo que el resto, las predicciones son más precisas y al tener el mejor R<sup>2</sup>, el modelo generaliza bien y por lo tanto reconoce patrones alimentándolo con datos desconocidos.

Por otro lado, según estas pruebas se observa que los modelo que mejores resultados dan a la hora de testear son los gaussianos, en este caso sobre todo los exponenciales y el de Matern 5/2 que salen como la mejor opción con el RMSE más bajo y el R<sup>2</sup> más próximo a 1. Para el entrenamiento el mejor método es el gaussiano exponencial GPR.

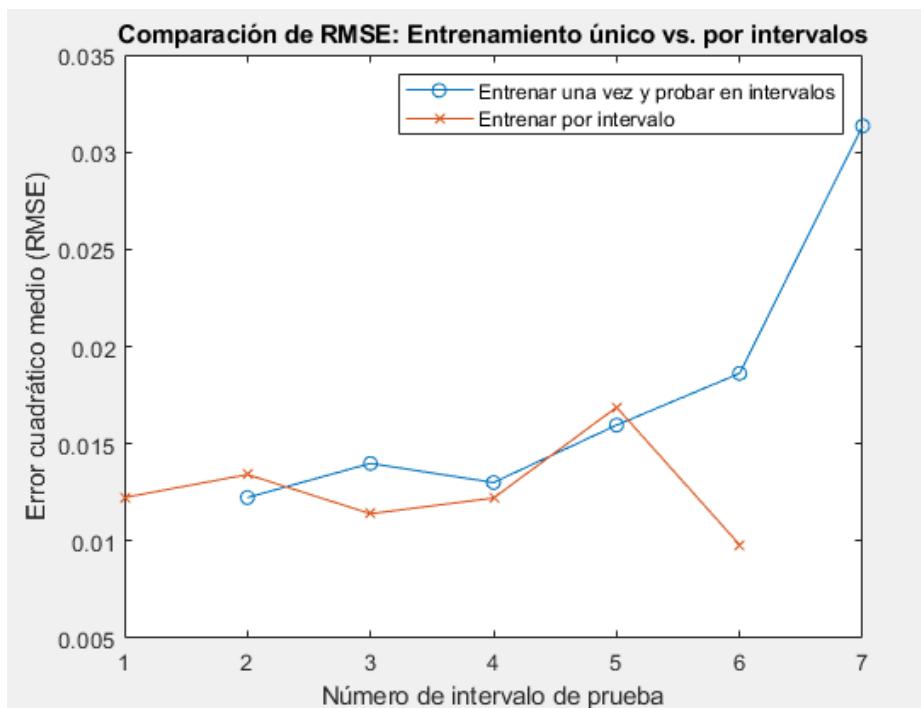
Ver el resto de las pruebas por conos en [ANEXO 3 CONOS → ENTRENAMIENTO Y TEST POR CONOS](#).

### 5.2.3 PÉRDIDA DE PRECISIÓN SIN ENTRENAMIENTO

En este apartado se trabaja con el archivo que contiene los datos de los conos A. Hay en total casi 12000 datos. Para comprobar la necesidad de estar constantemente entrenando los modelos se ha procedido por un lado a: entrenar los datos cada 1500

datos con un modelo gaussiano exponencial y testear con los 1500 datos siguientes y así sucesivamente; entrenar los primeros 1500 datos y a testear con los siguientes datos en intervalos iguales de manera iterativa.

Implementando los scripts correspondientes se obtiene lo siguiente:



**ILUSTRACIÓN 50 GRÁFICA DE LA INFLUENCIA DE ENTRENAMIENTOS PERIÓDICOS EN TESTEOS FRENTE A ENTRENAMIENTO ÚNICO DE UN INTERVALO**

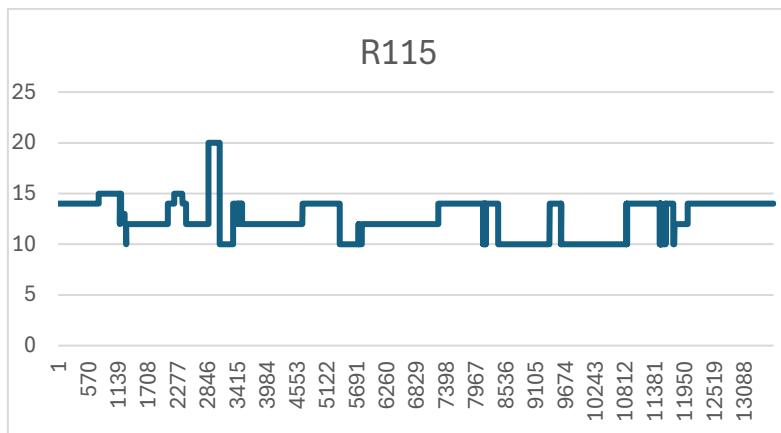
Observamos que si no se reentrena el modelo cada vez, el residuo aumenta progresivamente. Sin embargo, al reentrenar cada intervalo el residuo aumentará hasta cierto punto pero volverá a bajar. Se mantiene con el RMSE acotado en cambio en el caso de entrenamiento único conforme se testean más datos el RMSE aumenta cada vez más rápido. Por lo tanto la manera óptima de obtener buenos resultados es la de entrenar periódicamente para explicar y generalizar bien los datos que a priori se desconocen. En una línea de producción como la del objeto de este estudio es fundamental y los costes operativos que esto conlleva están más que justificados.

## 5.3 AROS

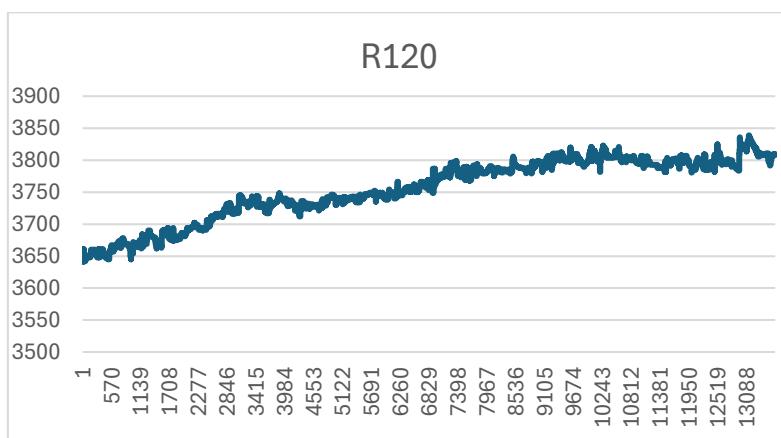
En este apartado se realiza un análisis previo de las variables que intervienen en los modelos de los aros. Se entrena los modelos cambiando ciertos parámetros como la frecuencia de entrenamiento.

### 5.3.1 ANÁLISIS PREVIO DE VARIABLES DE AROS

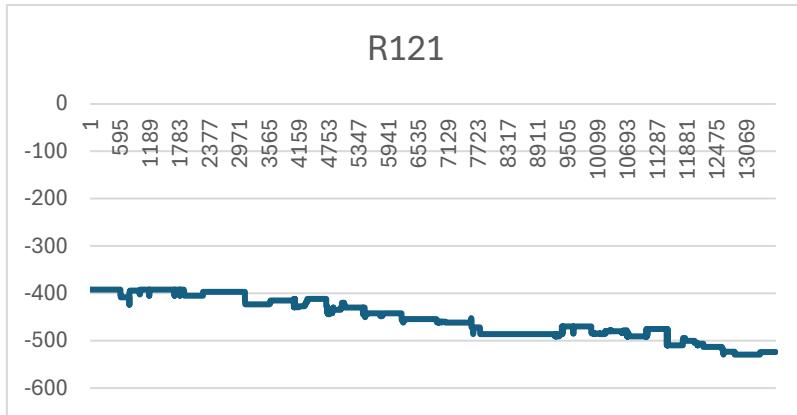
En este apartado se plantea gráficamente el comportamiento de las 5 variables influyentes en aros (se ha realizado un filtrado de datos debido a la existencia de valores anormales):



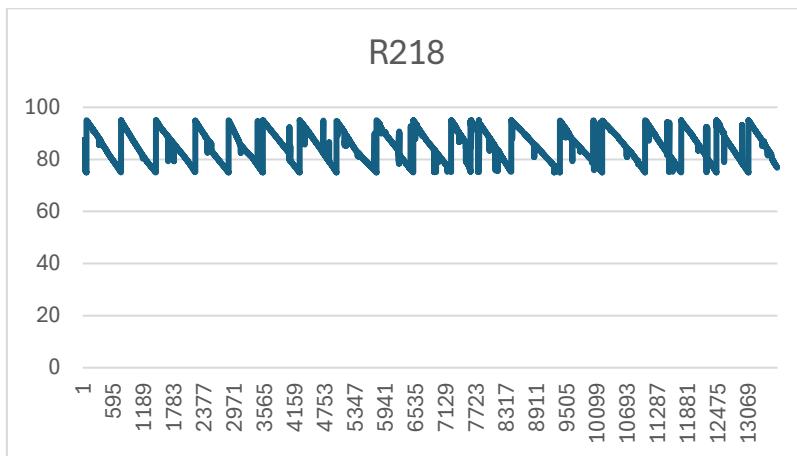
**ILUSTRACIÓN 51 GRÁFICA DEL COMPORTAMIENTO DE LA COMPENSACIÓN DE DIAMANTADO**



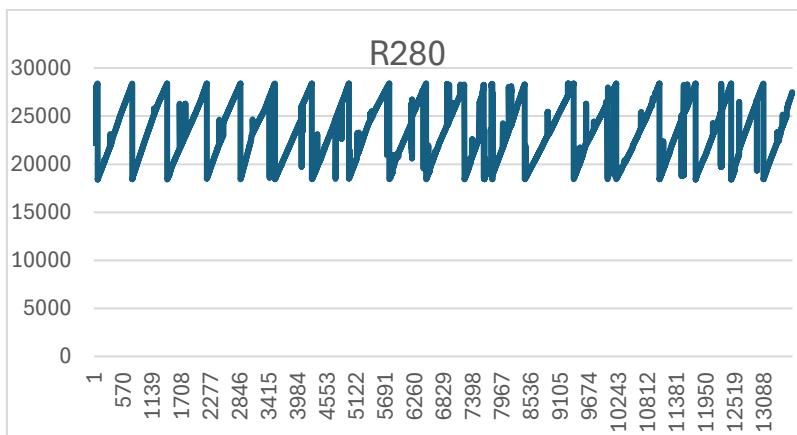
**ILUSTRACIÓN 52 GRÁFICA DEL COMPORTAMIENTO DE LA MEMORIA DE COMPENSACIÓN DE DIÁMETRO**



**ILUSTRACIÓN 53 GRÁFICA DEL COMPORTAMIENTO DE LA MEMORIA DE COMPENSACIÓN DE RECTIFICADO**



**ILUSTRACIÓN 54 GRÁFICA DEL COMPORTAMIENTO DEL DIÁMETRO ACTUAL DE MUELA**



**ILUSTRACIÓN 55 GRÁFICA DEL COMPORTAMIENTO DE LA POSICIÓN X DE RECTIFICADO**

Todas estas variables presentan un comportamiento estable o repetitivo en forma de patrones. Las variables R218 y R280 muestran una distribución de diente de sierra. Los

tramos en los que el valor de la variable crece o decrece rápidamente corresponden con los cambios de muela. Para el entrenamiento de modelos se considerará una delta de R280 y otra delta de R218 ya que es más fácil visualizar los cambios de muela y poder hacer mejor el entrenamiento y test por muelas. En este caso sí que tiene sentido hacer entrenamientos y test por muelas ya que hay muchos cambios de muela.

### 5.3.2 ENTRENAMIENTO Y TESTEO DE AROS

Se hacen pruebas, primero entrenando los datos con muelas y testeando con otras muelas posteriores, y después se hacen pruebas variando la frecuencia de entrenamiento diariamente, cada tres días, semanalmente, cada dos semanas.

A continuación se muestran los ejemplos de entrenar por muelas y de entrenar diariamente:

#### 5.3.2.1 ENTRENAMIENTO MUELA 36 Y TEST MUELA 37

 <b>2.13</b> SVM	RMSE (Test): 0.017741
Last change: Coarse Gaussian SVM	5/5 features
 <b>2.14</b> Efficient Linear	RMSE (Test): 0.020127
Last change: Efficient Linear Least Squares	5/5 features
 <b>2.15</b> Efficient Linear	RMSE (Test): 0.020089
Last change: Efficient Linear SVM	5/5 features
 <b>2.16</b> Ensemble	RMSE (Test): <b>0.016581</b>
Last change: Boosted Trees	5/5 features
 <b>2.17</b> Ensemble	RMSE (Test): 0.018580
Last change: Bagged Trees	5/5 features
 <b>2.18</b> Gaussian Process Regression	RMSE (Test): 0.018486
Last change: Squared Exponential GPR	5/5 features
 <b>2.19</b> Gaussian Process Regression	RMSE (Test): 0.020483
Last change: Matern 5/2 GPR	5/5 features
 <b>2.20</b> Gaussian Process Regression	RMSE (Test): 0.018564
Last change: Exponential GPR	5/5 features

**Model 2.16: Ensemble**  
Status: Tested

**Training Results**

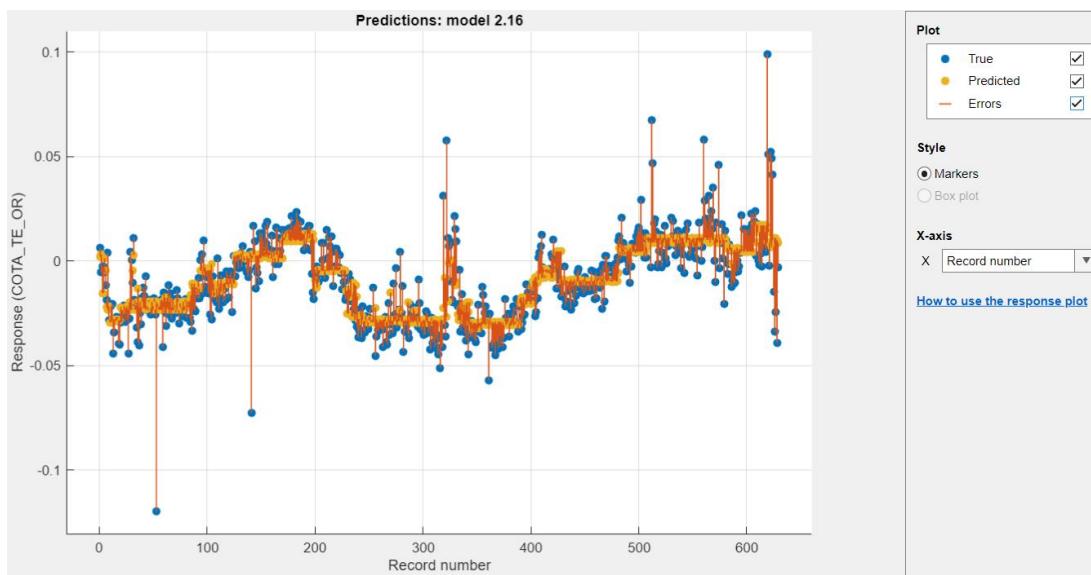
RMSE (Validation)	0.013562
R-Squared (Validation)	0.56
MSE (Validation)	0.00018393
MAE (Validation)	0.0091187
MAPE (Validation)	204.1%
Prediction speed	~3900 obs/sec
Training time	12.597 sec
Model size (Compact)	~156 kB

**Test Results**

RMSE (Test)	0.016581
R-Squared (Test)	0.30
MSE (Test)	0.00027492
MAE (Test)	0.013646
MAPE (Test)	353.1%

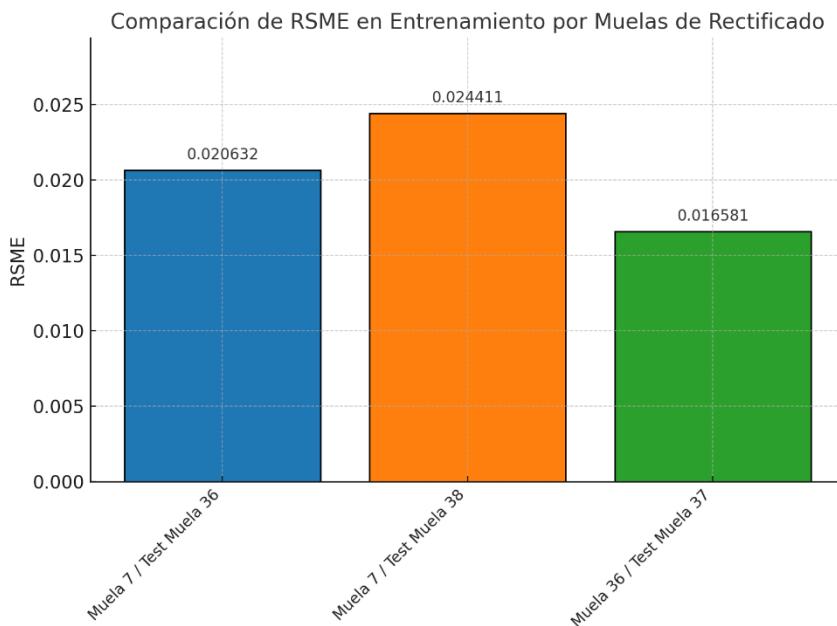
► **Model Hyperparameters**  
 ► **Feature Selection: 5/5 individual features selected**  
 ► **PCA: Disabled**  
 ► **Optimizer: Not applicable**

**TABLA 10 MODELOS DE ENTRENAMIENTO Y TEST DE AROS**



**ILUSTRACIÓN 56 GRÁFICA DE RESPUESTA DE LOS RESULTADOS REALES Y DE LAS PREDICCIÓNES**

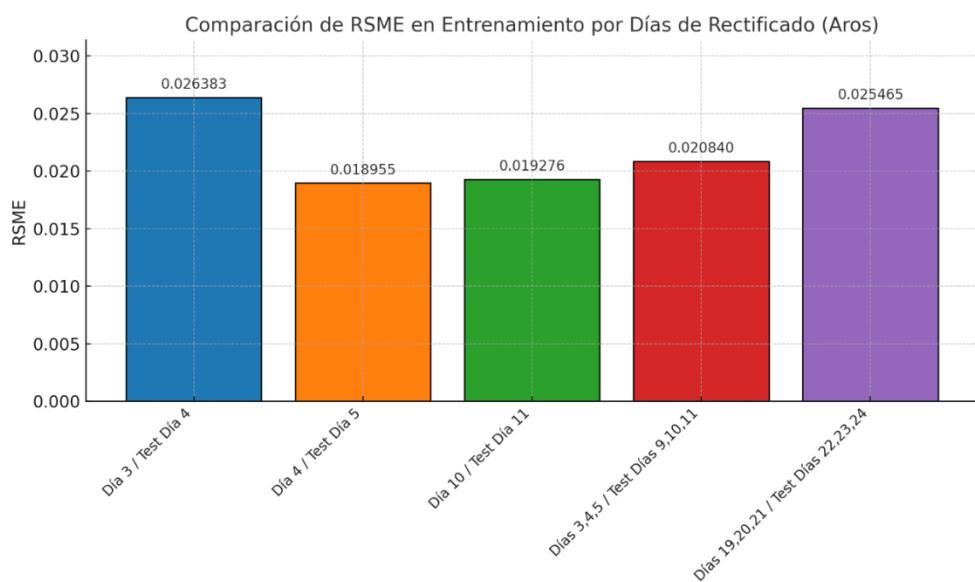
En este caso se hace un testeo con la muela consecutiva a la número 36, esta última es la que se ha entrenado. El residuo RMSE es bueno ya que es inferior a 20 micrómetros por lo tanto las predicciones de este modelo son buenas. Sin embargo, se ha procedido de la misma forma en [ANEXO 4 AROS → ENTRENAMIENTO Y TESTEO POR MUELAS](#), donde podemos observar que entrenando con la muela 7, si se testea con muelas posteriores lejanas por ejemplo la 36 y la 38, el RMSE cada vez es más alto y por lo tanto las predicciones cada vez son peores.



**ILUSTRACIÓN 57 RESUMEN COMPARATIVO DE ENTRENAMIENTOS Y TEST POR MUELAS**

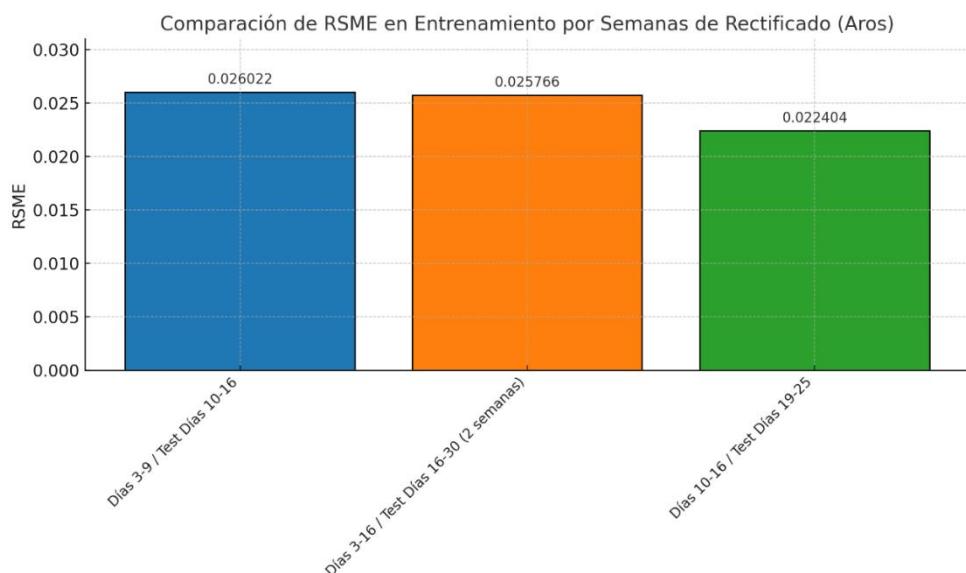
### 5.3.2.2 ENTRENO AROS DÍA 4 Y TEST DÍA 5

En este caso se entrena con los datos durante todo el tercer día de la toma de datos y se testea con el día siguiente para ver como de buenas son las predicciones. El residuo RMSE sigue siendo bueno porque está por debajo de los 20 micrómetros. En el [ANEXO 4 AROS → ENTRENAMIENTO Y TESTEO POR SEMANA Y POR DIAS](#) vemos que el entrenamiento del día 10 y testeo del 11 da un RMSE parecido pero que con los días 3 y 4 este aumenta por encima de los 20 micrómetros. Los entrenamientos y testeos cada tres días muestran resultados peores que los diarios anteriores.



#### ILUSTRACIÓN 58 RESUMEN COMPARATIVO DE ENTRENAMIENTOS Y TEST DIARIOS

Ver pruebas semanales en [ANEXO 4 AROS → ENTRENAMIENTO Y TESTEO POR SEMANA Y POR DIAS](#)



#### ILUSTRACIÓN 59 RESUMEN COMPARATIVO DE ENTRENAMIENTOS Y TEST SEMANALES

### 5.3.2.3 OBSERVACIONES CON LOS AROS

Por lo general los métodos de entrenamiento y testeo que mejores resultados dan son los de entrenar cada día o entrenar por muela ya que son los que muestran menores RMSE. Sin embargo, habría que valorar si es rentable entrenar por muelas o por días, tener algo más de precisión y por contra tener un mayor coste computacional o si es mejor entrenar semanalmente con menor coste computacional pero disminuyendo ligeramente la precisión de las predicciones. Aquí el problema aparente es que al testear los datos con aros el R2 es muy pequeño por lo que tiene un valor bastante malo. Esto puede ser debido a una falta de datos y presencia posible de ruido que hace que haya un sobreajuste y por lo tanto el modelo no generalice con los datos desconocidos, además de que ese sobreajuste tenga en cuenta el ruido. Esto hace que el modelo pierda credibilidad por lo que habría que mejorar la calidad y cantidad de los datos.

En una línea de producción de rodamientos, decidir con qué frecuencia entrenar un modelo de machine learning depende mucho de cómo funciona el proceso. Entrenar diariamente o por muela es útil si la producción cambia mucho de un día a otro, como cuando se trabaja con diferentes lotes de materiales o cuando las máquinas necesitan ajustes frecuentes. En este caso, el modelo puede adaptarse rápidamente a los cambios y detectar problemas, como un aumento en los defectos o el desgaste de una máquina, en tiempo casi real. Sin embargo, este enfoque también tiene inconvenientes, ya que entrenar todos los días requiere más recursos y tiempo, y existe el riesgo de que el modelo se ajuste demasiado a pequeñas variaciones que no son importantes, que es lo que pasa en este caso ya que el R2 de los testeos es muy bajo y por lo tanto malo.

Por otro lado, entrenar semanalmente puede ser más eficiente en términos de tiempo y costos, ya que el modelo analiza un conjunto de datos más completo y equilibrado. Este enfoque es ideal si el proceso es más estable y los cambios significativos ocurren de manera gradual. Además, los modelos entrenados semanalmente suelen ser más robustos, ya que no se ven afectados por pequeñas fluctuaciones que podrían ser ruido (en este caso también se ven afectados por el ruido y habría que obtener más datos y con mayor calidad). Sin embargo, el inconveniente es que, si ocurre algo inesperado en la producción, el modelo podría tardar varios días en reflejar ese cambio y ajustar sus predicciones.

La elección entre estos dos enfoques depende de cómo sea la producción. Si las condiciones cambian con frecuencia, el entrenamiento diario puede ser más adecuado. Pero si el proceso es más predecible, entrenar semanalmente será suficiente. A priori, el entrenamiento por muelas es el más preciso según estas pruebas por lo tanto quitando el resto de otros posibles factores se escogería este método. Tendríamos el coste computacional de entrenar por cada muela pero se podrían detectar mejor los errores en la línea.

Por otro lado, según estas pruebas, se observa que los modelos que mejores resultados dan a la hora de testear son los gaussianos, en este caso el cuadrático racional que sale como la mejor opción en 5 ocasiones por tener el RMSE más bajo. Para el entrenamiento el mejor método es el gaussiano exponencial GPR.

## 5.4 SIMULACIÓN GLOBAL (GD CON DATOS ANTERIORES)

En esta sección se procede a las pruebas del gemelo digital con datos de partida cambiando los parámetros a continuación:

### 5.4.1 CAMBIO EN LA ESTRATEGIA DE EMPAREJADO

Se procede a analizar lo que ocurre con respecto al emparejamiento de piezas según la combinación de tipos de emparejados permitidos: recto, en L y en V.

#### 5.4.1.1 TODOS LOS EMPAREJADOS PERMITIDOS

Esta ilustración muestra el script con todos los parámetros que se pueden modificar para ver como mejora o empeora el comportamiento de emparejado. En las tres primeras líneas de código se pueden modificar el número de factores en el modelo, las dos siguientes indican cada cuantos rectificados se puede ajustar la máquina M06 de aros y la M11 de conos, las 5 siguientes muestran si se utilizan distribuciones reales de aros o de conos al inicio de la simulación, las dos siguientes muestran la amplitud y el periodo para la distribución de conos y por último se muestran las estrategias de emparejado.

```

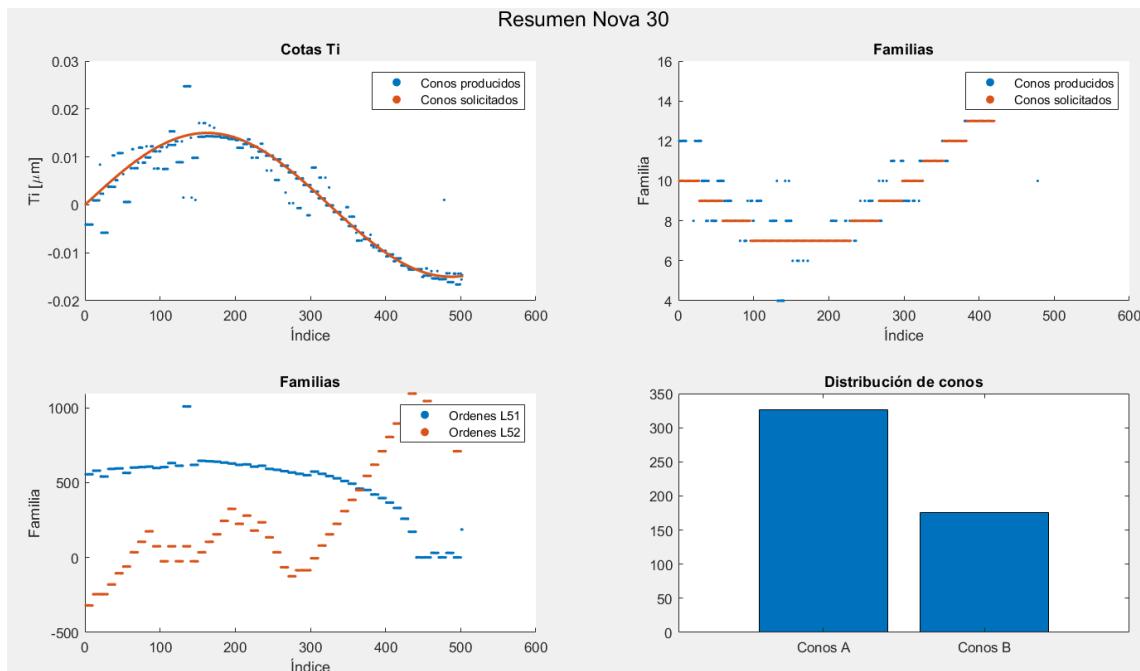
numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

grabar_videos = 0;
mostrar_figuras = 1;

```

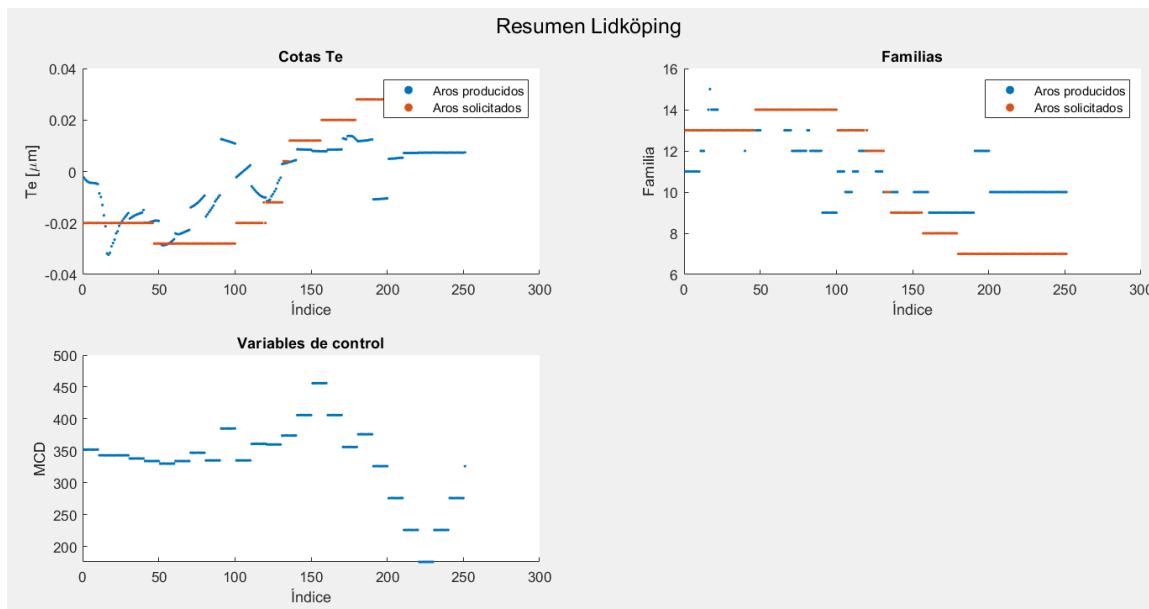
#### ILUSTRACIÓN 60 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL

Las siguientes ilustraciones muestran los resultados de la simulación. La siguiente ilustración muestra la gráfica de distribución de los conos solicitados frente a los conos producidos (primera gráfica arriba la izquierda) en función del output cota  $Ti,inv$ . Además se muestran la comparativa de las familias obtenidas de los conos solicitados frente a los producidos (gráfica de arriba a la derecha). Por último (abajo a la izquierda) se muestran las órdenes de las variables de control de los conos y la cantidad de conos de tipo A o de tipo B con la que se ha trabajado.



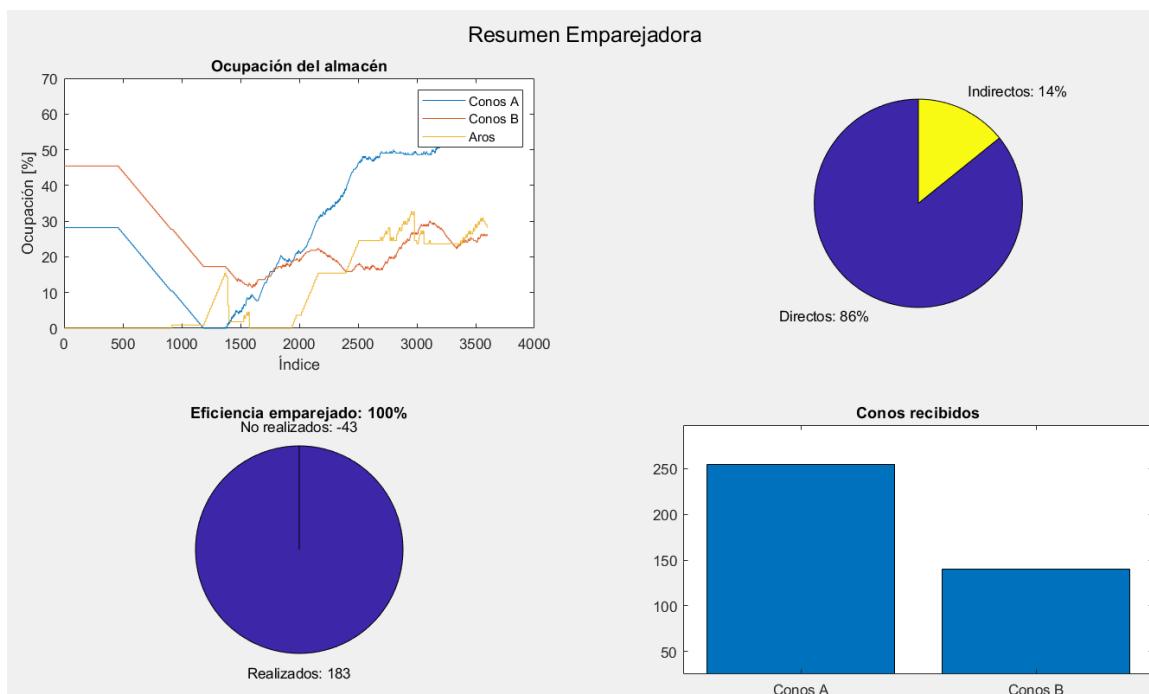
**ILUSTRACIÓN 61 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

La siguiente ilustración muestra algo parecido para los aros. La gráfica de arriba a la izquierda muestra también la distribución de aros producidos frente a la de aros solicitados en función del output cota  $Te$ . A continuación como en el caso anterior se muestran las variables de control y las familias de aros solicitados frente a los producidos.



**ILUSTRACIÓN 62 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

Finalmente se muestra el porcentaje de emparejados realizados y entre ellos, que porcentaje ha sido directo y cual indirecto. El directo si se emparejan los conos y los aros antes de almacenar alguna pieza y el indirecto si hay un almacenamiento previo al emparejado. Además se muestra la gráfica de ocupación de piezas en el almacén y la distribución de conos recibidos durante la simulación.

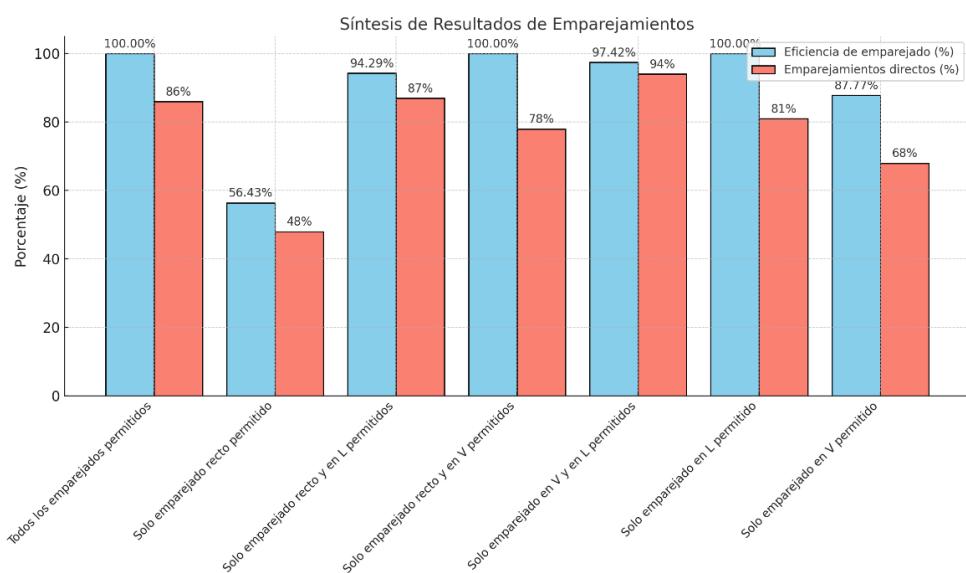


**ILUSTRACIÓN 63 RESULTADO DE LA SIMULACIÓN**

Las pruebas reflejan que permitiendo todos los tipos de emparejado, se realizan el 100% de estos. De manera directa se realiza un 86%, lo que significa que los aros y conos se emparejan antes de ser almacenados. De manera indirecta el 14%, lo que significa que este porcentaje de piezas de emparejan una vez almacenadas en el inventario. De todas las estrategias de emparejado, esta es la más efectiva ya que para un 100% de emparejamientos, tiene el porcentaje de emparejamientos directos.

Ver el resto de las pruebas de estrategias de emparejamiento en [ANEXO 5 GEMELO DIGITAL → GD CON DATOS DE PARTIDA → CAMBIO EN LA ESTRATEGIA DE EMPAREJADO](#).

La siguiente gráfica muestra un resumen de los resultados obtenidos con todas las pruebas:



**ILUSTRACIÓN 64 GRÁFICA RESUMEN DE CAMBIOS DE ESTRATEGIAS DE EMPAREJAMIENTO**

#### 5.4.2 CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25

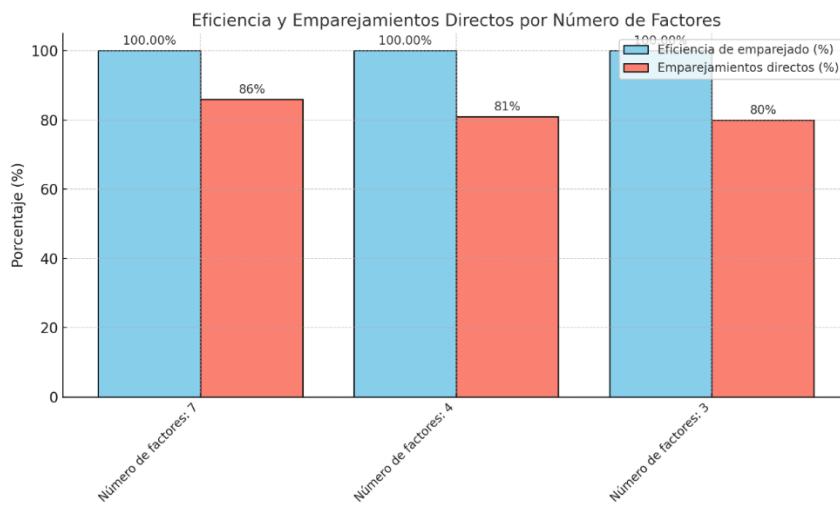
Se procede a cambiar la frecuencia de ajuste de las máquinas de rectificado.

Se observa que al aumentar la frecuencia de ajuste de M06 el número de emparejamientos indirectos pasa del 14% al 19% por lo tanto con respecto al caso anterior ( todos los emparejados permitidos con frecuencia de ajuste de aros de valor 10), este método es menos eficiente ya que se ocupará más espacio en el almacén. Las figuras correspondientes a este cambio de frecuencia se encuentran en el [ANEXO 5 GEMELO DIGITAL → GD CON DATOS DE PARTIDA → CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25](#).

### 5.4.3 CAMBIO EN EL NÚMERO DE FACTORES

Se procede a cambiar el número de factores que intervienen en los modelos de entrenamiento de aros y de conos. Ver todas las pruebas en el [ANEXO 5 GEMELO DIGITAL → GD CON DATOS DE PARTIDA → CAMBIO EN EL NÚMERO DE FACTORES](#).

Comparando la prueba de modelos de 7 factores con respecto a los de 4 y 3 factores presentes en los anexos correspondientes a dicha sección, se observa que a menor número de factores, mayores son los emparejamientos indirectos y por lo tanto la eficiencia de emparejado es menor. Al tratarse de factores influyentes cuantos más se eliminan peor es la eficiencia de emparejamiento tal y como se refleja en la siguiente gráfica de resultados:

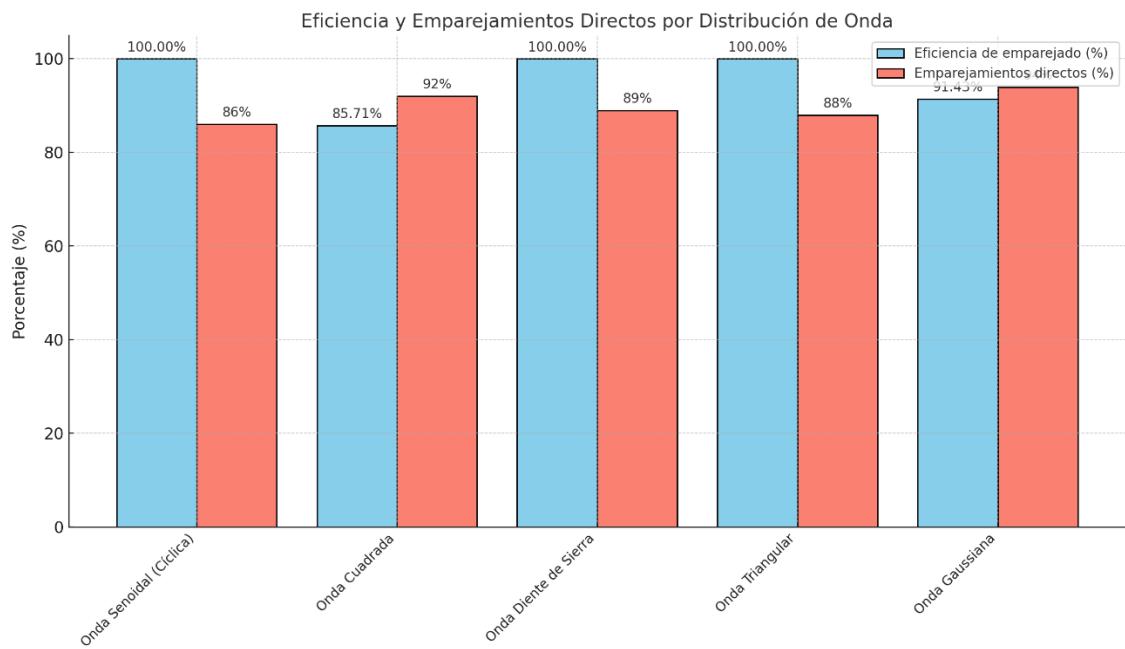


**ILUSTRACIÓN 65 GRÁFICA RESUMEN DEL CAMBIO DE NÚMERO DE FACTORES**

### 5.4.4 CAMBIO DE DISTRIBUCIÓN DE CONOS

Se procede a hacer cambios en las distribuciones de los conos modificando su función de onda.

Se observa que si cambiamos la distribución de los conos el resultado final a la hora de emparejar también cambia. La distribución que al parecer funciona mejor es la distribución de onda de diente de sierra, con la que se obtiene una eficiencia de emparejado del 100% y a la vez el menor porcentaje de emparejamientos indirectos realizados, solo un 11% (ver en el [ANEXO 5 GEMELO DIGITAL → GD CON DATOS DE PARTIDA → CAMBIO EN LA DISTRIBUCIÓN DE LOS CONOS](#)).



**ILUSTRACIÓN 66 GRÁFICA RESUMEN DE LOS RESULTADOS EN FUNCIÓN DE LA DISTRIBUCIÓN DE CONOS**

## 5.5 GD CON LOS DATOS NUEVOS

En esta sección se procede a las pruebas del gemelo digital con los datos y métodos nuevos cambiando los parámetros a continuación:

### 5.5.1 CAMBIO EN LA ESTRATEGIA DE EMPAREJADO

Se procede a analizar lo que ocurre con respecto al emparejamiento de piezas según la combinación de tipos de emparejados permitidos: recto, en L y en V.

Esta ilustración muestra todos los parámetros que se pueden modificar para ver como mejora o empeora el comportamiento de emparejado igual que en el caso anterior con los datos de partida.

```

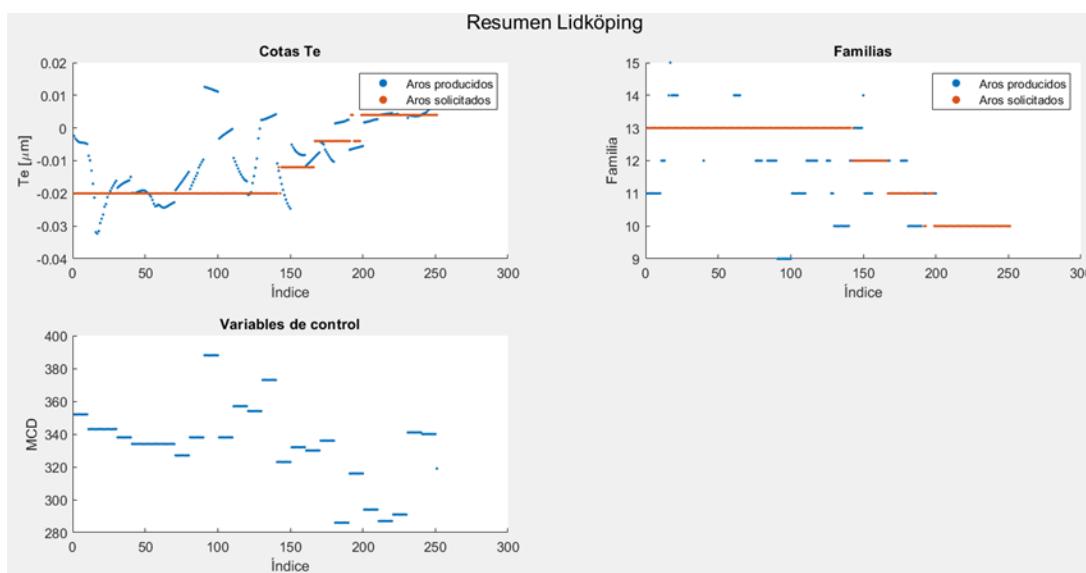
numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

grabar_videos = 0;
mostrar_figuras = 1;

```

#### **ILUSTRACIÓN 67 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL (DATOS NUEVOS)**

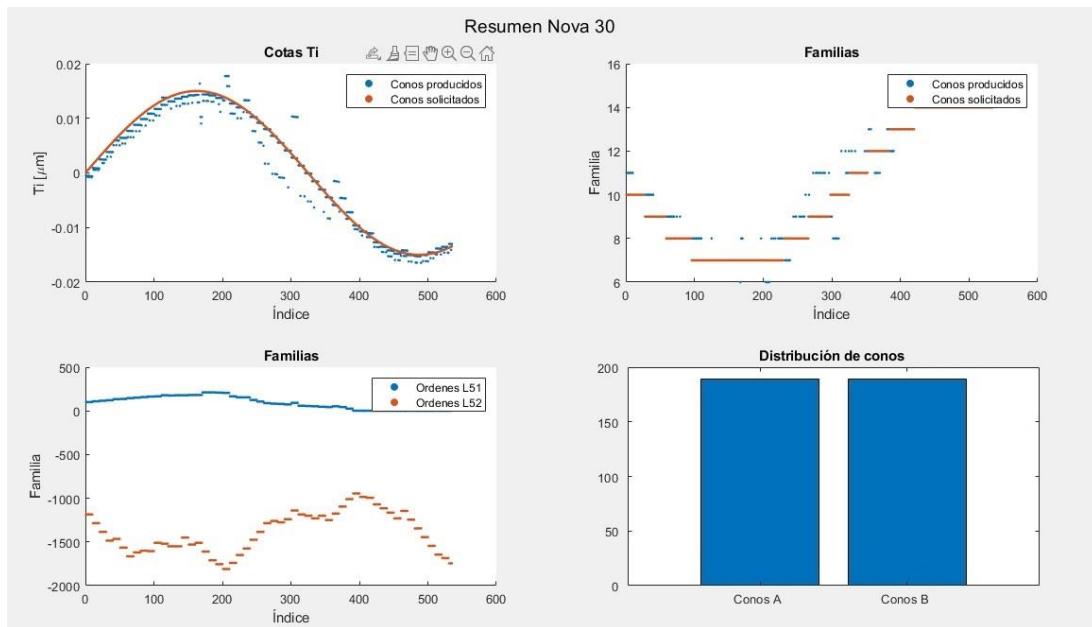
El comportamiento de los aros es similar al mencionado en el apartado con el gemelo digital antiguo. Las variables de control, en concreto la que se muestra aquí (R120) varía su valor en función de la producción de aros y de los aros solicitados. Esta variable dirige la producción de aros a lo largo de la simulación. En la siguiente gráfica se puede ver lo mismo que en el caso anterior: la Cota\_Te que es la variable de interés en los aros (output), las familias y la variable de control. Todo esto en función de lo que se pide y de lo que se produce.



#### **ILUSTRACIÓN 68 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

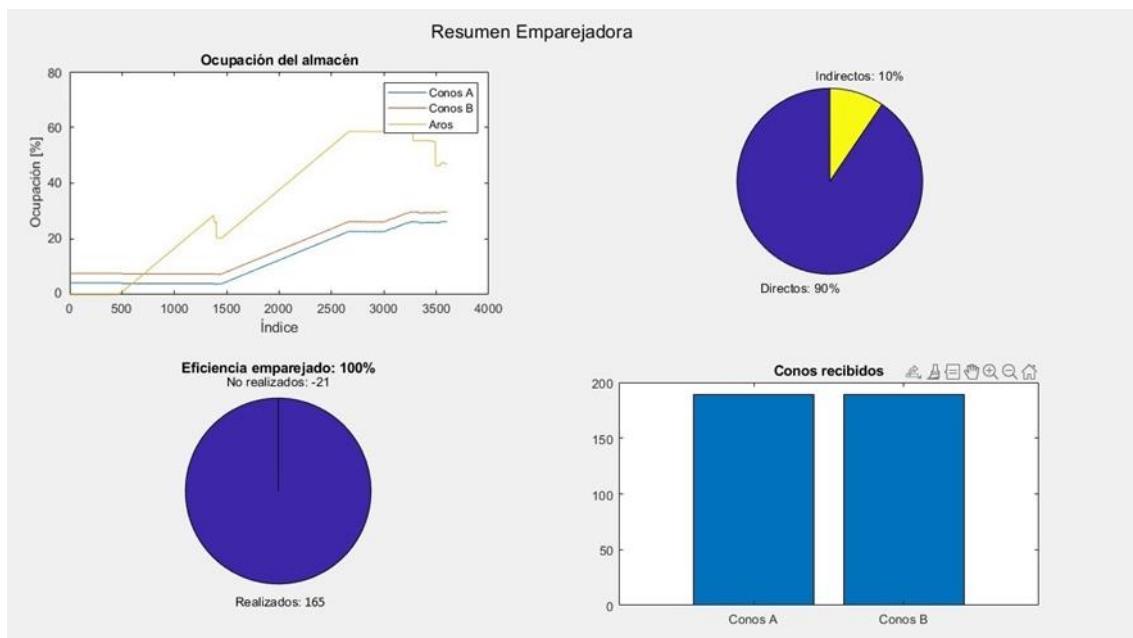
A continuación se aprecian las gráficas de los conos. La gráfica de la  $T_i$ , inversa sí que muestra cierta mejoría respecto al apartado anterior ya que su distribución de conos

producidos se ajusta visualmente más a la de conos solicitados. Todo este sistema está también regido por sus variables de control L51 y L52.



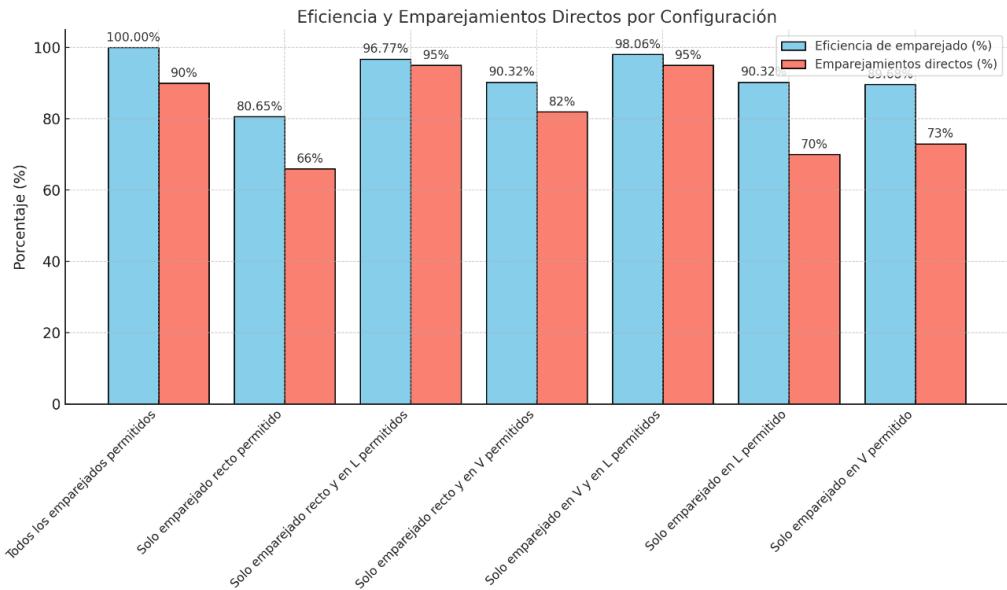
**ILUSTRACIÓN 69 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

Finalmente el resultado final muestra una clara mejora respecto del apartado anterior, es decir un 14% frente a un 10% de emparejamientos indirectos en este caso de estudio. La eficiencia de emparejado se mantiene firme en el 100%.



**ILUSTRACIÓN 70 RESULTADO DE LA SIMULACIÓN CON DATOS NUEVOS**

Se observa que los mejores resultados se obtienen cuando todos los tipos de emparejamiento están permitidos como cabe esperar. Ver el resto de las pruebas en el [ANEXO 5 GEMELO DIGITAL → GD CON LOS DATOS NUEVOS → CAMBIO EN LA ESTRATEGIA DE EMPAREJADO](#).



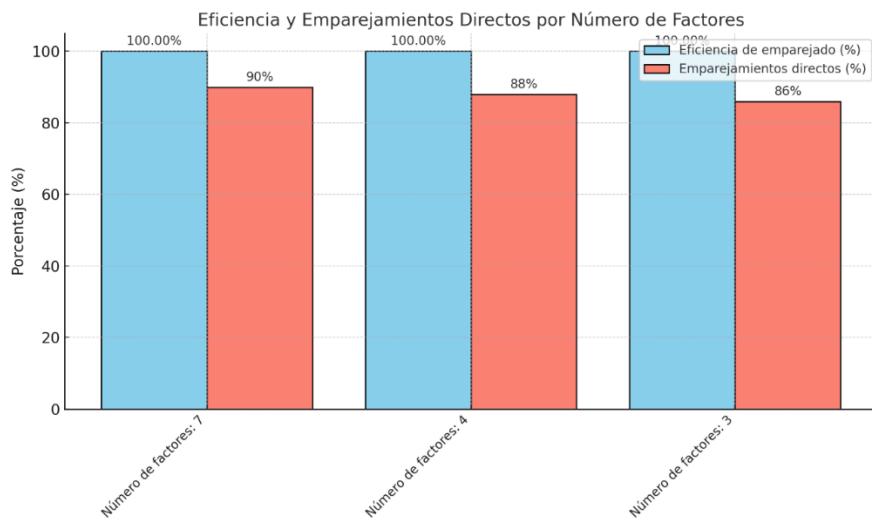
**ILUSTRACIÓN 71 GRÁFICA RESUMEN DE CAMBIOS EN LA ESTRATEGIA DE EMPAREJAMIENTO**

### 5.5.2 CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25

En este apartado se varía la frecuencia de ajuste cada 25 rectificados en lugar de cada 10 rectificados. Al igual que en el apartado con el gemelo digital anterior, al aumentar la frecuencia de ajuste de la rectificadora de aros la eficiencia de emparejamiento empeora ya que con frecuencia de 10 rectificados tenemos un 10% de emparejamientos indirectos frente a un 14% con frecuencia de 25 rectificados. Ver el resto de las pruebas en el [ANEXO 5 GEMELO DIGITAL → GD CON LOS DATOS NUEVOS → CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25](#).

### 5.5.3 CAMBIO EN EL NÚMERO DE FACTORES

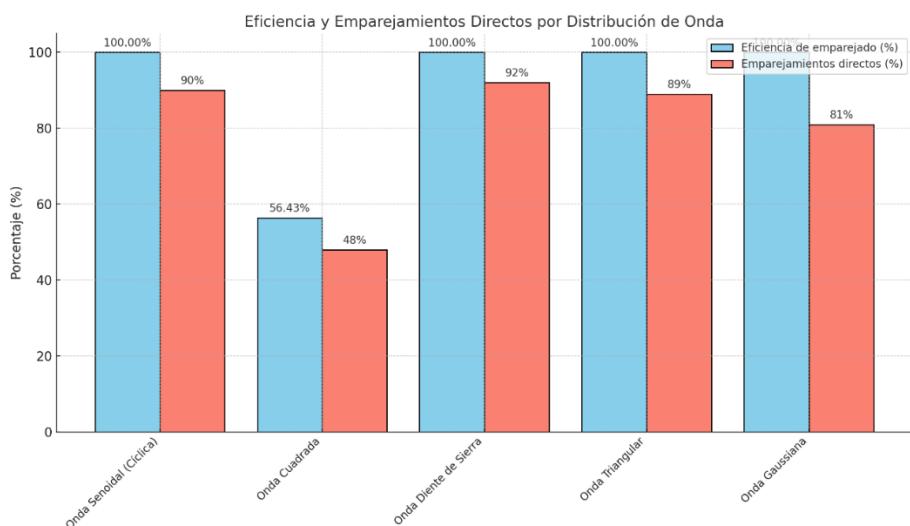
Se ha procedido a comparar modelos con 7,4 y 3 factores. Ocurre lo mismo que con el gemelo digital con datos anteriores, es decir que a mayor número de factores, mejor eficiencia de emparejado ya que se explica mejor el modelo con todos los factores relevantes presentes. Ver el resto de las pruebas en el [ANEXO 5 GEMELO DIGITAL → GD CON LOS DATOS NUEVOS → CAMBIO EN EL NÚMERO DE FACTORES](#).



**ILUSTRACIÓN 72 GRÁFICA RESUMEN DE CAMBIOS EN EL NÚMERO DE FACTORES**

#### 5.5.4 CAMBIO DE DISTRIBUCIÓN DE CONOS

En este apartado se proceden a realizar las simulaciones correspondientes con el gemelo digital modificado con los datos nuevos que se han manejado hasta el momento. El gemelo digital con los datos nuevos en general obtiene mejores resultados que con el gemelo anterior ya que hay mayor porcentaje de emparejamientos directos y la eficiencia de emparejado es más elevada. La distribución de diente de sierra es la que nuevamente presenta mayor eficiencia de emparejado, solo un 8% de los emparejamientos son indirectos frente al 11% en el caso anterior con los datos y modelos anteriores. Ver el resto de las pruebas en el [ANEXO 5 GEMELO DIGITAL → GD CON LOS DATOS NUEVOS → CAMBIO EN LA DISTRIBUCIÓN DE LOS CONOS](#).



**ILUSTRACIÓN 73 GRÁFICA RESUMEN DE CAMBIOS EN LA DISTRIBUCIÓN DE CONOS**

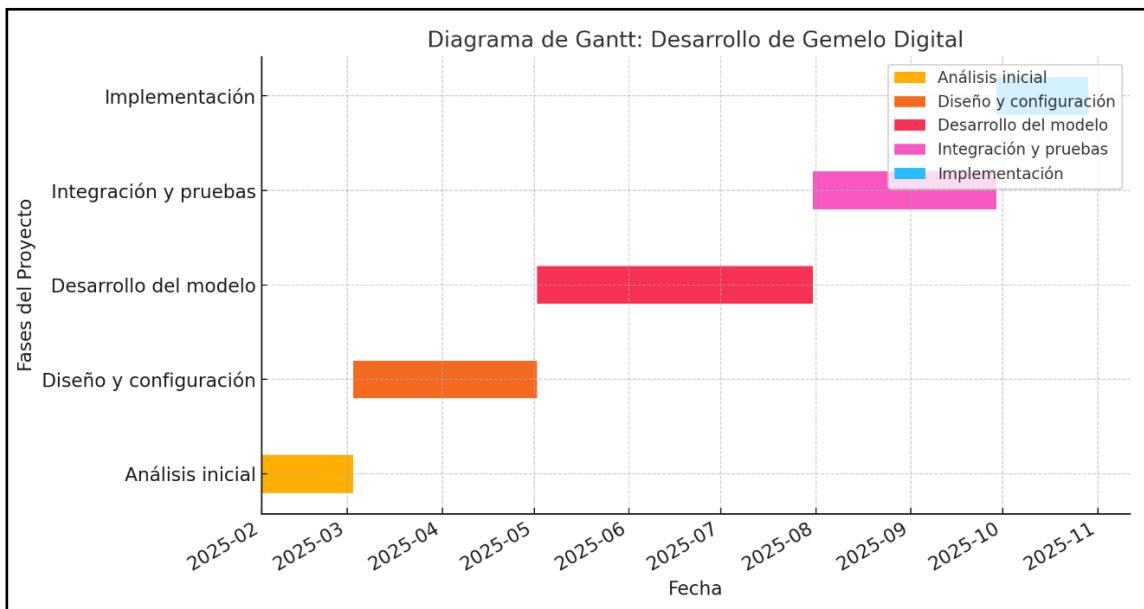
## 6. ESTIMACIÓN ECONÓMICA Y PLANIFICACIÓN

Un proyecto de gemelo digital conlleva elementos de coste esenciales, tanto directos como indirectos. Los gastos directos incluyen hardware y dispositivos, tales como sensores de vibración, temperatura y fuerza, junto con PLCs, infraestructura de servidores y almacenamiento, con una estimación de entre 10000€ y 30000€. Además, abarca programas informáticos, que incluyen licencias de herramientas CAD/CAE y plataformas de simulación como MATLAB o Simulink, con un costo que oscila entre 5000€ y 15000€. Respecto al equipo, es imprescindible tener ingenieros expertos en modelado y especialistas en análisis de datos y programación, lo que supone un desembolso de entre 40000€ y 80000€, en función de la duración del proyecto. Los gastos indirectos comprenden capacitación, con una inversión de 5000€ para formar al personal, y mantenimiento, con actualizaciones regulares del gemelo digital que se actualizan que cuestan entre 5000€ y 10000€ anuales.

Categoría	Coste (€)	Descripción
Ingeniería y Desarrollo	40000	Horas de diseño y desarrollo del gemelo digital, pruebas y validaciones.
Infraestructura y Equipos	50000	Compra e instalación de equipos y servidores necesarios.
Mantenimiento y Soporte	10000	Costes anuales para garantizar el correcto funcionamiento.
Licencias de Software	15000	Adquisición de software necesario para simulaciones y análisis.
Formación y Capacitación	8000	Capacitación del personal en el uso del gemelo digital.
Contingencias	5000	Fondo para imprevistos o gastos no planificados.

**TABLA 11 COSTES PARA EL DESARROLLO DEL GEMELO DIGITAL**

El desarrollo de un gemelo digital se organiza en etapas sucesivas que incluyen actividades concretas para lograr las metas del proyecto. El procedimiento se inicia con un análisis preliminar, en el que se establecen las metas, se analiza el proceso de múltiples fases y se escogen indicadores esenciales como la temperatura y la vibración. Seguidamente, se realiza el diseño y configuración, que comprende el diseño del modelo CAD/CAE y la configuración de sensores y hardware. Durante la etapa de creación del modelo, se lleva a cabo el modelado tanto dinámico como físico del proceso, además de la puesta en marcha de simulaciones. Luego, en el proceso de integración y evaluación, el gemelo digital se vincula con información real, garantizando su funcionalidad y mejora. Finalmente, durante la implementación, se pone en marcha el sistema y se otorga capacitación al personal.



**ILUSTRACIÓN 74 DIAGRAMA DE GANTT DEL PROYECTO**

## 7. CONCLUSIONES

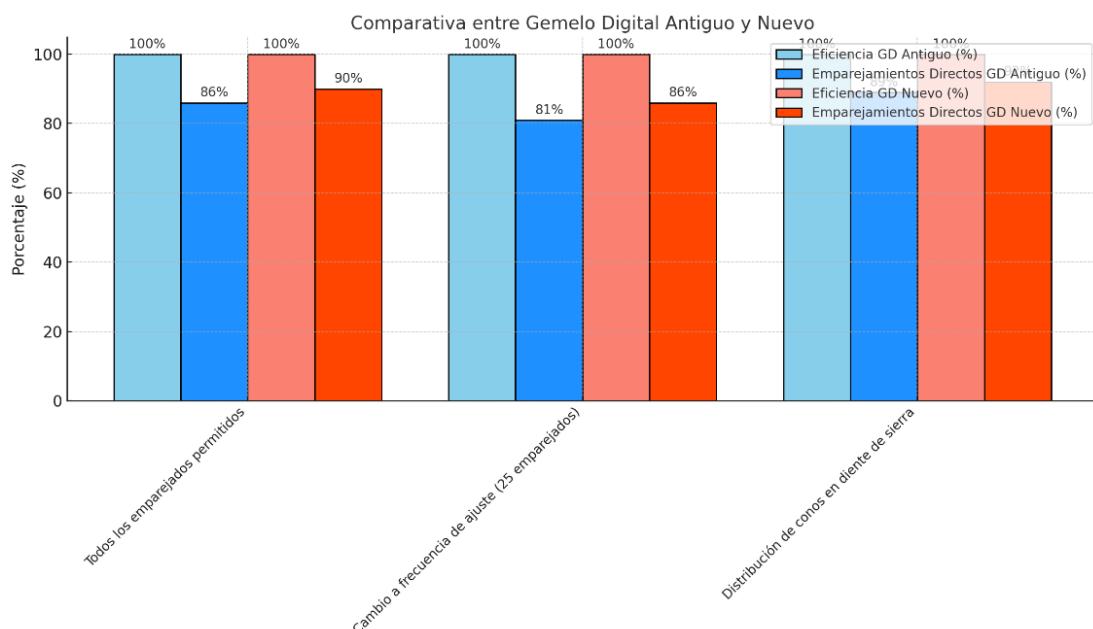
Este trabajo muestra el proceso seguido para determinar los mejores modelos de entrenamiento y de test para los gemelos digitales mencionados. Inicialmente se ha trabajado con modelos de entrenamiento con datos sintéticos para ver la influencia del ruido y de las variables no influyentes en los modelos. Se obtiene que a mayor factor de ruido mayor es el RMSE y por lo tanto peor es el modelo entrenado. Además si se incluyen más variables espurias el modelo tiene RMSE y las predicciones son peores. Esto ocurre debido a un sobreajuste con datos irrelevantes en el modelo.

Más adelante, se ha trabajado con diferentes métodos de entrenamiento y test de los aros y de los conos, para ver cuáles de ellos son más eficientes. Generalmente, los mejores modelos de entrenamiento son los gaussianos exponenciales en ambos casos. Sin embargo, para los test los mejores modelos para los aros son los gaussianos racionales cuadráticos GPR, y para los conos los gaussianos Matern 5/2.

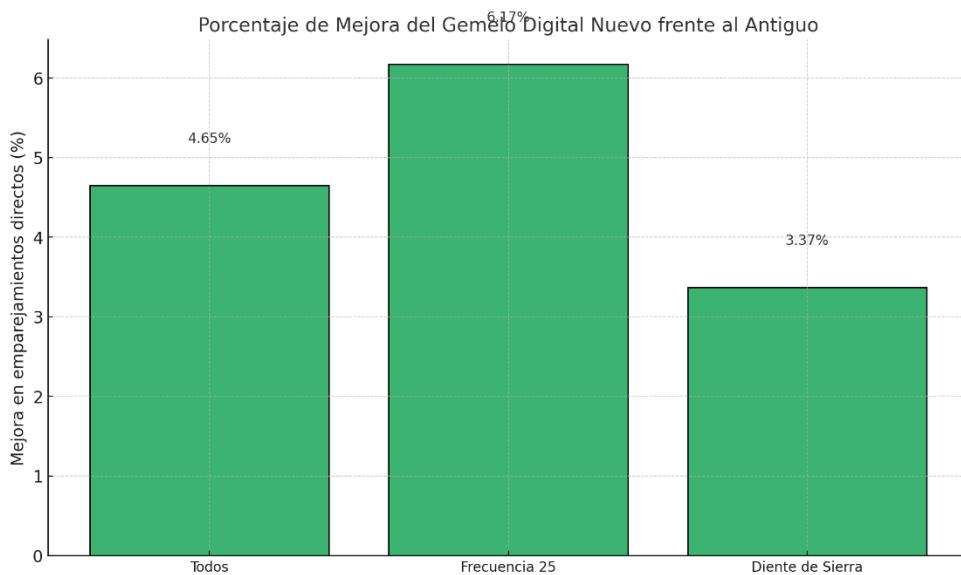
Finalmente, se ha analizado el rendimiento del gemelo digital offline que ya había sido creado con anterioridad y se realizan cambios sobre este con los inputs antiguos mediante distintas estrategias. Con estos cambios se ha comprobado cuál es la manera más eficiente de trabajar sobre este GD. Posteriormente, se ha creado un gemelo digital modificando el anterior y que pueda leer los inputs y los modelos nuevos para que siga los mismos procedimientos con los datos nuevos. Se compara la eficiencia del GD nuevo con el GD anterior que recibía otros datos de entrada anteriores.

- Según los resultados obtenidos el mejor modelo de entrenamiento para los aros es el entrenamiento por muelas.
- El mejor modelo de entrenamiento de los conos es el entrenamiento diario.

Si comparamos los mejores resultados del GD anterior con los mejores resultados del GD nuevo, con estos datos actualizados obtenemos lo siguiente:



**ILUSTRACIÓN 75 GRÁFICA COMPARATIVA ENTRE LOS MEJORES RESULTADOS DE AMBOS GD**



**ILUSTRACIÓN 76 GRÁFICA DEL PORCENTAJE DE MEJORA DEL GD NUEVO VS GD ANTERIOR**

Aplicando este gemelo digital a la línea se obtendría un 4,65% de mejora permitiendo todos los emparejamientos respecto al GD anterior. Si además de esto incluimos una distribución de conos en diente de sierra la eficiencia del GD podría aumentar aún más ya que con esta distribución se obtienen mejores resultados que con una distribución senoidal.

La principal problemática de este trabajo ha sido que en algunos datos de aros y conos actualizados faltaban días o datos de alguna variable. Se ha llevado a cabo un filtrado de datos para las muelas de rectificado de aros porque había valores de variables anormales.

Se plantean por último algunas posibles líneas de trabajo futuras:

- Analizar la optimización simultánea de varias estrategias de emparejado teniendo en cuenta la eficiencia, la calidad y los tiempos de ciclo. Además también se podría analizar el cómo equilibrar la frecuencia de ajuste de las máquinas para aumentar la productividad y minimizar el desgaste.
- Estudiar sistemas de control adaptativos que ajusten frecuencias de las máquinas y distribuciones de conos en función de datos en tiempo real. Se podría también investigar algoritmos para realizar cambios de estrategia basándose en la demanda y patrones productivos.
- Diseño de distribuciones óptimas mediante algoritmos que generen estas distribuciones en función de las características del rodamiento y de las necesidades del cliente.
- Investigación en implementar un ecosistema de gemelos digitales en la línea de producción que estén enfocados en diferentes factores que la afectan, tanto internas (ruido, máquinas) como externas a la línea (demanda, costes) para que se comuniquen entre ellos.

## 8. BIBLIOGRAFÍA

- 1) [1] Prakash M. Jadhav, Surajkumar G. Kumbhar, R.G. Desavale, Shubham B. Patil, Distributed fault diagnosis of rotor-bearing system using dimensional analysis and experimental methods, Measurement, Volume 166, 2020, 108239, 10.1016/j.measurement.2020.108239.
- 2) [2] Sebastian Schwendemann, Zubair Amjad, Axel Sikora, A survey of machine-learning techniques for condition monitoring and predictive maintenance of bearings in grinding machines, Computers in Industry, Volume 125, 2021, 103380, 10.1016/j.compind.2020.103380.
- 3) [3] Brosed, F.J.; Victor Zaera, A.; Padilla, E.; Cebrián, F.; Aguilar, J.J. In-process measurement for the process control of the real-time manufacturing of tapered roller bearings. MATERIALS. 11 - 8, pp. 1371. 2018. ISSN 1996-1944.
- 4) [4] Sadeghi F, Jalalahmadi B, Slack T S, Raje N, Arakere N K. A review of rolling contact fatigue. ASME Transactions on Tribology 2009; 131:041403-1-15.
- 5) [5] Bertolini, M.; Mezzogori, D.; Neroni, M.; Zammori, F. Machine Learning for industrial applications: A comprehensive literature review. Expert Syst. Appl. 2021, 175, 114820. 10.1016/j.eswa.2021.114820.
- 6) [6] Chen, T.; Sampath, V.; May, M.C.; Shan, S.; Jorg, O.J.; Aguilar Martín, J.J.; Stamer, F.; Fantoni, G.; Tosello, G.; Calaon, M. Machine Learning in Manufacturing towards Industry 4.0: From 'For Now' to 'Four-Know'. Appl. Sci. 2023, 13, 1903. 10.3390/app13031903.
- 7) [7] Shan Ren, Yingfeng Zhang, Yang Liu, Tomohiko Sakao, Donald Huisingsh, Cecilia M.V.B. Almeida, A comprehensive review of big data analytics throughout product lifecycle to support sustainable smart manufacturing: A framework, challenges and future research directions, Journal of Cleaner Production, Volume 210, 2019, Pages 1343-1365, 10.1016/j.jclepro.2018.11.025.
- 8) [8] Wan J, Li X, Dai H-N, Kusiak A, Martinez-García M and Li D 2021 Artificial-Intelligence-Driven Customized Manufacturing Factory: Key Technologies, Applications, and Challenges in Proceedings of the IEEE 109 377. 10.1109/JPROC.2020.3034808.
- 9) [9] Kritzinger W, Karner M, Traar G, Henjes J and Sihn W 2018 Digital Twin in manufact.: A categorical literature review and classification IFAC-PapersOnLine 51 1016-1022. 10.1016/j.ifacol.2018.08.474.
- 10) [10] Domínguez, J., Esteban, A., Romeo, J. A., Cebrián, F., Santo Domingo, S., and Aguilar, J. J. Development of Machine Learning prediction models for their integration in a Digital Twin for a tapered roller bearing production line. IOP Conference Series: Materials Science and Engineering. 2021. Vol. 1193, No. 1, p. 012108. 10.1088/1757-899X/1193/1/012108.

- 11) <https://es.mathworks.com/discovery/linear-regression.html>
- 12) Resumen proceso producción Z3 (Archivo proporcionado por la EINA)
- 13) Conos 200910\_Patrones\_fabricacion (Archivo proporcionado por la EINA)
- 14) Aros 200826\_InformeAnalisisVariables (Archivo proporcionado por la EINA)
- 15) Presentacion Expertia 20241128 (Archivo proporcionado por la EINA)
- 16) MESIC\_presentation (Archivo proporcionado por la EINA)
- 17) MESIC23 correccionesAjustado (Archivo proporcionado por la EINA)
- 18) Charla de Ingeniero de FERSA en la EINA
- 19) Explicaciones visita a FERSA

**Último acceso a estos documentos: 24/01/2025**

## 9. ANEXOS

En esta sección están presentes todas las gráficas e ilustraciones a las que se hace referencia en la memoria.

### ANEXO 1 FABRICACIÓN DE AROS Y CONOS

En este anexo se recogen los datos restantes con respecto al proceso de fabricación de rodamientos. [\*Archivo fuente: Resumen proceso producción Z3\*](#)

#### AROS

##### 4.2.3.1 MÁQUINA DE MARCAJE DE AROS, Z3M01

En esta estación, los aros recibidos directamente del proveedor se marcan con un código datamatrix único de 20 dígitos, similar al aplicado en los conos. Este código garantiza la trazabilidad unitaria de los aros a lo largo de toda la línea de producción.

##### 4.2.3.2 MÁQUINA DE CONTROL DE DUREZA LAMUCE-IBG, Z3M02

En esta estación se realiza un ensayo de dureza para verificar que el aro cumple con las especificaciones establecidas. Los aros que no alcanzan los parámetros requeridos, ya sea por exceso o insuficiencia de dureza, son descartados automáticamente y no se procesan.

##### 4.2.3.3 MÁQUINA DE RECTIFICADO LAMUCE 33, Z3M03

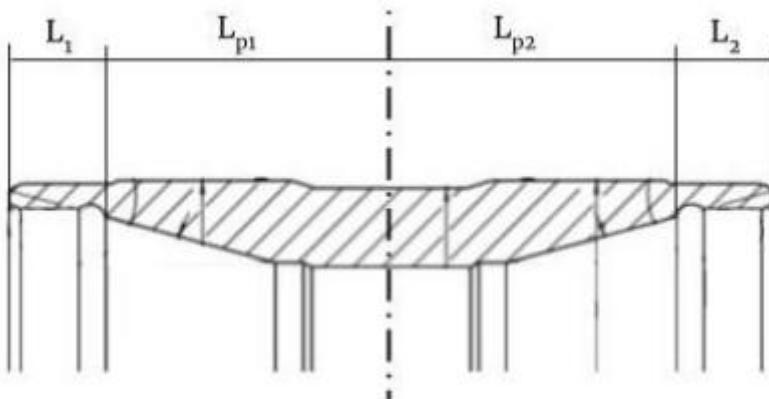
En esta estación se rectifican las caras superior e inferior del aro exterior recibido del proveedor. A diferencia de los conos, los aros no se pueden planear en la máquina DISKUS debido a su baja estabilidad geométrica. Esto se debe a que son piezas relativamente pesadas (~3 kg), esbeltas y con una superficie de contacto limitada en sus caras, lo que generaría defectos si se usara esta máquina.

El proceso de rectificado tiene como objetivos principales:

- Centrado de las pistas del aro exterior
- Normalmente, las pistas del aro no están centradas debido a una distribución desigual del material en los extremos. Esto genera una desviación, donde las

dimensiones de los extremos del aro ( $L_1$  y  $L_2$ ) no coinciden, resultando en pistas no alineadas ( $L_{p1} \neq L_{p2}$ ).

- En esta estación se rectifican las caras superior e inferior para corregir esta desviación, logrando que las pistas queden perfectamente centradas en el aro ( $L_{p1} = L_{p2}$ ).
- Para ello, se calcula previamente la cantidad exacta de material que debe rectificarse en cada cara.
- Cumplimiento de la altura total del aro exterior (C)
- Además del centrado de las pistas, se garantiza que el aro cumpla con la especificación de altura total. Si el aro ya presenta pistas centradas al llegar a la estación, ambas caras se rectifican de manera uniforme hasta alcanzar la altura especificada.



**ILUSTRACIÓN 77 CORTE DEL ARO. SI LOS EXTREMOS,  $L_1$  Y  $L_2$ , NO TIENEN LA MISMA DIMENSIÓN (POR EXCESO O DEFECTO DE MATERIAL), LAS PISTAS NO ESTÁN CENTRADAS ( $L_1 \neq L_2$ ).**

**Archivo fuente:** [Resumen proceso producción Z3](#)

La estación está organizada en dos procesos principales:

- Subestación Z3M03.1: En esta etapa se mide el aro (altura y diámetro de ambas pistas) y se calcula el sobrematerial que debe ser eliminado en cada cara para alcanzar las especificaciones.
- Subestación Z3M03.2: Se lleva a cabo el rectificado final para corregir tanto el centrado de las pistas como la altura total del aro.

Este enfoque asegura que cada aro procesado cumpla con las especificaciones de calidad y precisión requeridas para su ensamblaje en las etapas posteriores.

#### 4.2.3.4 MÁQUINA DE RECTIFICADO LAMUCE 34 (Z3M04)

**Archivo fuente:** [Resumen proceso producción Z3](#)

En esta estación se lleva a cabo el rectificado de las caras exteriores del aro, ajustando su diámetro exterior (D). Aunque esta operación podría realizarse en máquinas anteriores de Fersa fuera de Z3, se decidió reacondicionar una máquina ESTARTA para integrarla en la línea y mejorar la eficiencia del proceso.

Sin embargo, esta máquina representa el verdadero cuello de botella de la línea debido a sus ineficiencias operativas. En condiciones ideales, el cuello de botella debería estar en el rectificado de conos B en la máquina NOVA 30.

Dado que el diámetro exterior (D) es una de las dimensiones críticas en el montaje, esta estación cuenta con una máquina de control dimensional inmediatamente posterior. Si esta estación detecta alguna deriva o desviación en las medidas, se genera una orden correctora para rectificar las piezas en Z3M04.

#### **4.2.3.5 MÁQUINA DE CONTROL DIMENSIONAL LAMUCE (Z3M05)**

Esta estación realiza el control del rectificado efectuado en la Z3M04. Su función principal es medir con precisión las dimensiones obtenidas y descartar las piezas que no cumplen las especificaciones establecidas.

#### **4.2.3.6 MÁQUINA DE RECTIFICADO LIDKÖPING 35 (Z3M06)**

La estación Z3M06 es una de las más relevantes de la línea, ya que en ella se rectifican las pistas del aro, ajustando sus dimensiones y la distancia entre ellas. Este rectificado es crucial, ya que afecta directamente a parámetros clave como:

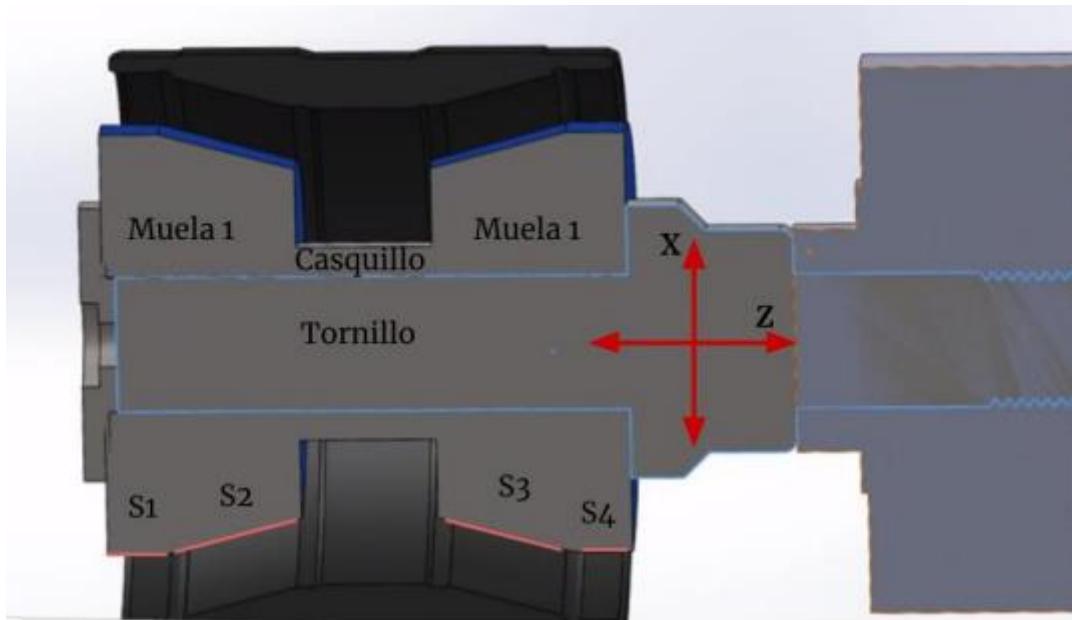
- La distancia entre pistas.
- La precisión en la  $T_i$  inversa.
- La holgura axial del rodamiento final.

Se ha determinado que cada micrómetro de desviación en el diámetro rectificado genera una variación de 4 micrómetros en la holgura axial, destacando la precisión necesaria en esta estación.

#### **Configuración de la Muela**

La máquina utiliza una muela específica con cuatro superficies funcionales:

- S2 y S3: Superficies destinadas al rectificado de las pistas, que contienen el negativo del perfil del aro.
- S1 y S4: Superficies encargadas del rectificado de las áreas extremas del orificio.
- La muela está dividida en dos partes, que funcionan como unidades independientes separadas por un casquillo y montadas sobre un tornillo.



**ILUSTRACIÓN 78 MUELA DE LA RECTIFICADORA LIDKÖPING 35.**

*Archivo fuente: [Resumen proceso producción Z3](#)*

### Alineación y Ajuste de la Distancia entre Pistas

La distancia entre las pistas del aro depende de dos factores:

- La alineación de la muela con el aro a lo largo del eje Z.
- El desplazamiento de la muela en el eje X.

El ajuste de esta distancia se realiza teniendo en cuenta las piezas que se encuentran en el pulmón de almacenamiento al final de la línea, para garantizar la compatibilidad durante el emparejamiento y ensamblaje final. Estas operaciones aseguran que las piezas rectificadas cumplan con los altos estándares de precisión necesarios para el montaje del rodamiento. La holgura axial de los conjuntos depende directamente de las dimensiones de los conos y los aros. En la rectificadora LIDKÖPING, se tiene control directo sobre una de las variables más críticas en este aspecto: la distancia entre pistas.

El rectificado debe ajustarse para obtener una distancia entre pistas que permita, al emparejar los aros con los conos disponibles al final de la línea, una holgura axial dentro de las tolerancias establecidas. Por lo tanto, esta dimensión se convierte en el parámetro más importante y conscientemente controlado durante el proceso. Por ejemplo, si al final de la línea se acumulan conos con una Ti\_inversa elevada, la rectificadora LIDKÖPING recibe la instrucción de mecanizar distancias entre pistas mayores para asegurar que estos conos puedan emparejarse correctamente con los aros disponibles.

### Automatización del Modelo Digital

El modelo digital debe determinar automáticamente la posición relativa entre la muela y el aro (ejes X y Z) para garantizar que las distancias entre pistas sean compatibles con los conos que se están rectificando de forma paralela o que ya están disponibles al final de la línea.

### **Condiciones Previas al Rectificado**

Para asegurar un correcto rectificado de la distancia entre pistas, es esencial que:

- Las pistas del aro estén perfectamente centradas: Esto debe haberse logrado previamente en la estación LAMUCE 33. Si las pistas están descentradas, el efecto será equivalente a una mala alineación del eje Z.
- El eje Z esté correctamente alineado: Ambas condiciones son imprescindibles para obtener un rectificado preciso y mantener las tolerancias establecidas.

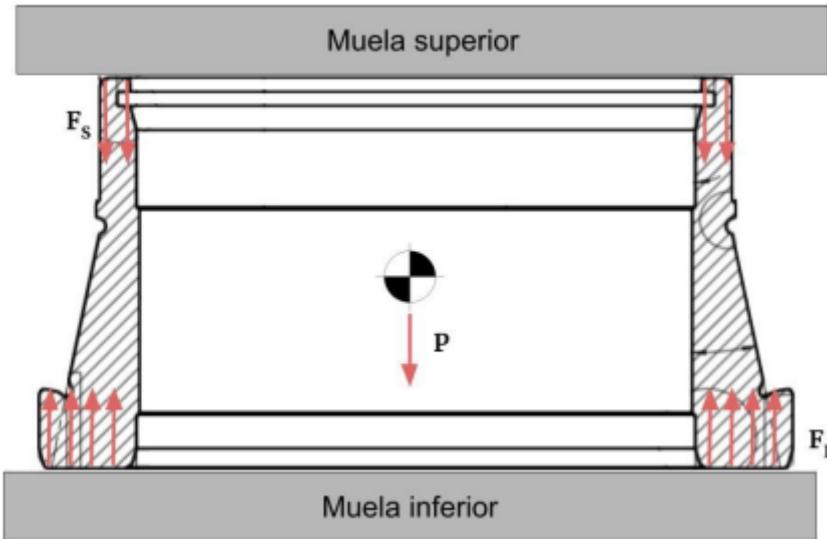
### **4.2.3.7 SUPERACABADO EN BLUE HORSE OR (Z3M07)**

Esta estación realiza el superacabado de las pistas del aro, minimizando la rugosidad de las superficies tras el rectificado. Aunque el proceso es similar al realizado en los conos, las pistas de los aros presentan un perfil abombado (en lugar de logarítmico). El superacabado permite partir de rugosidades iniciales de varios micrómetros y reducirlas hasta alcanzar valores en el rango de décimas de micrómetro. Este acabado final es crucial para garantizar el correcto funcionamiento y la durabilidad del rodamiento ensamblado.

## **CONOS**

### **4.2.4.1 PREPROCESADO DE CONOS EN ZC**

En la Zona Central (ZC), los conos se someten a un primer rectificado mediante las máquinas DISKUS, tal como se ilustra en la siguiente figura. Este proceso tiene como objetivo preparar los conos para las operaciones posteriores en la línea Z3. El rectificado realizado por las máquinas DISKUS abarca ambas caras del cono (superior e inferior) de forma simultánea, lo que introduce ciertas complicaciones técnicas.



**ILUSTRACIÓN 79 RECTIFICADO DE LAS CARAS DEL CONO EN DISKUS. FI: FUERZA EJERCIDA EN LA CARA INFERIOR; FS: FUERZA EJERCIDA EN LA CARA SUPERIOR; P: PESO DEL CONO.**

Archivo fuente: [Resumen proceso producción Z3](#)

Distribución de Fuerzas durante el Rectificado:

- Debido al peso del cono, las fuerzas generadas en el proceso no son iguales en ambas caras. La fuerza ejercida por la muela inferior (F<sub>i</sub>) supera a la fuerza de la muela superior (F<sub>s</sub>), tal como se muestra en la ilustración.
- Además, la presión ejercida por unidad de superficie es mayor en la cara inferior, lo que puede generar ligeras diferencias en el acabado de ambas superficies.
- Este proceso inicial es clave para garantizar una preparación uniforme de los conos antes de los rectificados posteriores en la línea Z3, donde se afinarán las dimensiones y se ajustarán las especificaciones necesarias.

#### Repetibilidad en DISKUS y Necesidad de Homogeneización

El proceso de rectificado en DISKUS presenta limitaciones en términos de repetibilidad, lo que genera irregularidades y diferencias dimensionales entre los conos A y B. Estas discrepancias hacen necesario un proceso de homogeneización en la línea Z3 para garantizar una calidad uniforme en los conos procesados.

Además, las diferencias entre los conos A y B requieren parámetros de rectificado específicos, así como la identificación precisa del tipo de cono. Para optimizar la eficiencia del proceso, en DISKUS se trabaja de manera secuencial, procesando primero todos los conos de un tipo antes de proceder con los del otro, evitando el orden aleatorio que sí ocurre en Z3.

#### 4.2.4.2 MÁQUINA DE MARCAJE DE LOS CONOS, Z3M10

La estación Z3M10 es la encargada de recibir los conos provenientes de DISKUS (ZC). A diferencia de DISKUS, los conos ingresan a esta máquina de forma aleatoria y no agrupados por tipo. En esta estación, cada cono es marcado con un datamatrix único de 20 dígitos, grabado con tecnología láser. Este código permite:

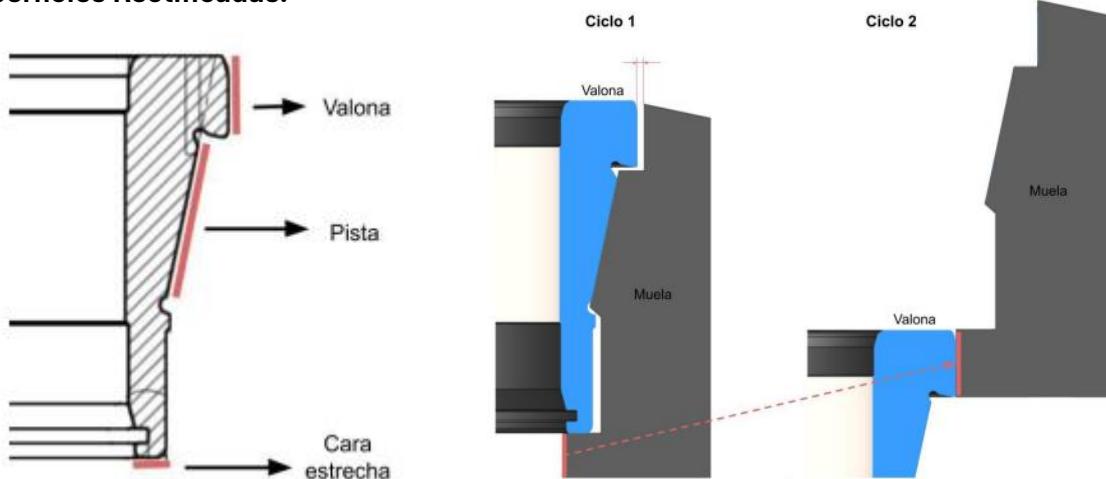
- La identificación del cono.
- Su trazabilidad a lo largo de toda la línea de producción.

Durante el proceso de marcaje, también se identifica el tipo de cono (A o B) y se registra en la variable “CATALOGO\_NR”. Esta información queda asociada al datamatrix y permite el seguimiento del tipo de cono desde esta etapa en adelante.

#### 4.2.4.3 MÁQUINA DE RECTIFICADO NOVA 30, Z3M11

La máquina NOVA 30 es una de las estaciones clave dentro de la línea Z3, ya que en ella se ajustan dimensiones fundamentales que tienen un impacto directo en la holgura axial (HA) del conjunto final.

##### Superficies Rectificadas:



**ILUSTRACIÓN 80 SUPERFICIES A RECTIFICAR EN NOVA 30 Y RECTIFICADO SIMULTÁNEO DE LAS 3 SUPERFICIES DEL CONO A.**

*Archivo fuente: Resumen proceso producción Z3*

NOVA 30 trabaja sobre tres áreas principales del cono:

- La valona.
- La pista ( $d_1$ ).
- La cara estrecha del cono.

El correcto rectificado de estas superficies es crucial para cumplir con las especificaciones dimensionales y funcionales del cono, asegurando así el ajuste necesario para su posterior ensamblaje con los aros.

### **Influencia del Rectificado en la Holgura Axial**

El proceso de rectificado en NOVA 30 tiene un impacto directo en dimensiones clave que afectan al correcto funcionamiento del rodamiento:

- Altura Total (B): Ajustada durante el rectificado de la cara estrecha del cono.
- Altura Ti\_inversa: Influida tanto por el rectificado de la cara estrecha como de la pista.

Ambas dimensiones son fundamentales para garantizar que la holgura axial del conjunto esté dentro de las tolerancias especificadas. Debido a su importancia, es imprescindible realizar un control exhaustivo del rectificado en esta estación.

### **Diferencias Dimensionales entre Conos A y B**

Un desafío crítico en esta máquina es la diferencia en las dimensiones de la valona entre los conos A y B. La valona del cono A tiene un diámetro mayor que la del cono B, lo que impide que ambos tipos de conos puedan ser rectificados de la misma manera. Esta diferencia dimensional exige parámetros de rectificado específicos para cada tipo de cono, añadiendo un nivel de complejidad al proceso. El diseño de la operación debe contemplar estas particularidades para garantizar que las dimensiones críticas, como la Ti\_inversa y la altura total, se ajusten adecuadamente en ambos tipos de conos.

El proceso de rectificado en la NOVA 30 requiere de un diseño meticuloso y una operación rigurosa, dado que las diferencias entre los conos A y B afectan tanto al procedimiento como a la productividad de la línea.

### **Consideraciones para el Rectificado de Conos B**

Dimensiones de la Superficie Inferior de la Muela. La superficie inferior de la muela debe ser 6 mm mayor que las empleadas en la máquina NOVA 9 (Z0) para permitir el correcto rectificado de la valona de los conos B. Esto asegura que la valona de los conos B sea mecanizada adecuadamente durante el segundo ciclo.

### **Importancia de la Identificación del Tipo de Cono**

Error al procesar un cono B como A:

- La valona no se rectificaría, ya que no se ejecutaría el segundo ciclo, comprometiendo la calidad del cono.

- Error al procesar un cono A como B:
- La muela colisionaría con la valona durante el segundo ciclo, causando daños graves a la máquina.
- Tiempo de Ciclo
- El tiempo de rectificado de un cono B es 8 segundos mayor que el de un cono A, debido a la necesidad de realizar dos ciclos.
- Esto hace que el rectificado de conos B sea el cuello de botella teórico de la línea.

### **Sistemas de Identificación y Control**

Antes de que el cono entre en la máquina, se verifica su tipología mediante sistemas de identificación automática. En caso de fallo del sistema de control, la máquina se detiene automáticamente para evitar daños.

### **Operaciones Manuales**

Cuando se introduce un cono manualmente, la máquina realiza una comprobación adicional para determinar el tipo antes de iniciar el rectificado.

### **Influencia del posicionamiento de la muela, dimensiones clave influenciadas**

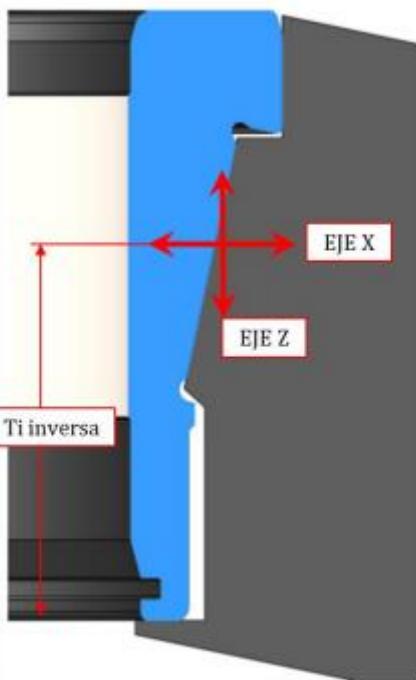
La posición de la muela durante el rectificado afecta:

- La altura total del cono (B).
- La distancia entre la cara ancha del aro exterior y la cara estrecha del cono (Ti\_inv).
- Impacto en la Holgura Axial (HA)

Tanto B como Ti\_inv son dimensiones críticas que influyen directamente en la holgura axial (HA), esencial para la calidad del rodamiento y el ensamblaje eficiente de conjuntos.

### **Ajustes Dinámicos para Optimización**

Mediante pequeños ajustes en la posición de la muela, se pueden obtener valores precisos de B y Ti\_inv, lo que permite controlar la HA. Esto facilita el ensamblaje de todas las piezas disponibles en el pulmón al final de la línea, asegurando un proceso productivo y eficiente. En la máquina NOVA 30, el proceso de rectificado está altamente influenciado por la precisión en los ajustes de posición relativos entre el cono y la muela, definidos por los ejes X y Z:



**ILUSTRACIÓN 81 EJES DE NOVA 30. LOS CONOS SE MUEVEN EN EL EJE X Y LA MUELA EN EL EJE Z.**  
**NÓTESE QUE LA DIMENSIÓN MARCADA NO ES LA  $T_{I\_INV}$  SINO AQUELLA QUE TIENE REPERCUSIÓN SOBRE LA  $T_{I\_INV}$ .**

Archivo fuente: [Resumen proceso producción Z3](#)

### Movimiento y Ajustes Críticos

#### Movimientos Relativos:

- Conos: Se desplazan a lo largo del eje X.
- Muela: Se ajusta en el eje Z.

Estos movimientos coordinados son esenciales para garantizar un rectificado correcto.

#### Interdependencia Dimensional:

- En NOVA 30, cualquier modificación en las dimensiones sobre los ejes X o Z repercuten directamente en otras dimensiones clave, como B y  $T_{I\_INV}$ . Esto hace que los ajustes en estos ejes sean críticos y deban realizarse con extrema precisión.

### Objetivo de los Modelos Digitales

Los modelos digitales deben automatizar el ajuste de la posición relativa entre el cono y la muela para garantizar:

- Dimensiones B y Ti\_inv acordes a las piezas disponibles en el pulmón de ensamblaje al final de la línea.
- Adaptación en tiempo real a las necesidades del proceso, optimizando la calidad y eficiencia.

#### **Influencia en Ti\_inv**

No todas las dimensiones influyen de igual forma sobre Ti\_inv. Es fundamental identificar cuáles tienen un mayor impacto para priorizar los ajustes:

- B y la posición de la muela en Z tienen una influencia directa y significativa.
- Ajustes en X afectan más al contacto entre la muela y el cono, determinando la calidad superficial y posibles desviaciones.

Este enfoque dinámico y automatizado asegura que las piezas procesadas en la máquina NOVA 30 cumplan con las tolerancias requeridas, contribuyendo a una holgura axial controlada y un ensamblaje eficiente.

#### **4.2.4.4 MÁQUINA DE RECTIFICADO NOVA 31, Z3M12**

La máquina NOVA 31 es responsable del rectificado del agujero interior de los conos, una dimensión crítica para el montaje de los rodamientos.

##### Aspectos destacados:

###### Diámetro interior homogéneo:

- Ambos tipos de conos (A y B) tienen el mismo diámetro interior (d), por lo que no es necesaria la identificación del tipo de cono en esta estación.
- Control de calidad automatizado:
- Una estación de control dimensional (Z3M13) sigue inmediatamente al rectificado para verificar la calidad y detectar cualquier deriva o sesgo.

###### Ajustes correctores automáticos:

- Si se detectan desviaciones, se envían órdenes a NOVA 31 para realizar correcciones.
- Variables no registradas:
- Esta máquina no genera datos de variables de funcionamiento.

#### **4.2.4.5 MÁQUINA DE CONTROL DIMENSIONAL DEL AGUJERO DEL CONO, Z3M13**

Esta estación verifica las dimensiones del agujero interior de los conos y asegura que cumplen con los valores de referencia establecidos.

##### Funcionamiento:

- Identificación automática del tipo de cono:

- El palpador mide el principio y el final de la zona rectificada del agujero interior y, a partir de estas características, identifica si se trata de un cono A o B.

#### Comparación con valores de referencia:

- Los valores medidos se comparan con las especificaciones predefinidas para determinar si el cono cumple las tolerancias.

#### Correcciones activas:

- Si se detectan desviaciones, se envían órdenes correctoras a la estación de rectificado (NOVA 31).

### **4.2.4.6 MÁQUINA DE RECTIFICADO RIFA32, Z3M14**

La máquina RIFA32 rectifica las testas (zona de apoyo de los rodillos en el cono).

#### Detalles clave:

##### Dimensiones iguales:

- Las testas de los conos A y B son idénticas, por lo que no es necesaria la identificación del tipo de cono.

##### Dimensiones no críticas:

- Este proceso no afecta a dimensiones críticas, y por ello no se registran datos de esta estación.

### **4.2.4.7 MÁQUINA DE SUPERACABADO BLUE HORSE IR, Z3M15**

En esta máquina se realiza el superacabado de las pistas y testas para reducir la rugosidad superficial y mejorar el rendimiento del rodamiento.

#### Características del proceso:

##### Reducción de rugosidad:

- La rugosidad inicial (varios micrómetros) se reduce a valores de décimas de micra, tal como se aprecia en el perfil logarítmico tras el proceso.

##### Menor impacto dimensional:

- Aunque se elimina una pequeña cantidad de material, las dimensiones críticas no se ven significativamente afectadas, por lo que no se registran datos de esta estación.

##### Tolerancias ajustadas para muelas nuevas:

- Cuando la muela es nueva, su abrasividad es mayor. Para evitar sobrepuertos, se limitan ligeramente las tolerancias especificadas, creando un margen de seguridad.

## ENSAMBLAJE Y ALMACENAMIENTO

### 4.2.5.1 ESTACIONES DE LAVADO R&S (Z3M08, Z3M16, Z3M20)

Estas estaciones eliminan impurezas como grasa, aceite o taladrina adheridas a las superficies de conos, aros y conjuntos interiores:

- Z3M08: lava los aros mediante hidrocarburo.
- Z3M16: lava los conos mediante ultrasonidos.
- Z3M20: lava los conjuntos interiores (cono, rodillos y jaula) antes del ensamblaje con los aros.

### 4.2.5.2 MESAS ACUMULADORAS DE CONOS R&S

Las dos mesas acumuladoras trabajan en paralelo y están diseñadas para:

- Separar conos A y B: Permiten clasificar los conos y alimentarlos de forma alternada a las estaciones finales.
- Evitar acumulaciones desproporcionadas: Garantizan un flujo equilibrado de conos A y B, necesario para un ensamblaje eficiente.
- Identificación de conos: Al igual que en NOVA 30, estas mesas identifican el tipo de cono antes de clasificarlos.

### 4.2.5.3 ESTACIÓN R&S DE CONTROL DIMENSIONAL DEL CONO (Z3M17)

Es la última estación antes del ensamblaje en la que se realiza un control dimensional general para descartar piezas defectuosas.

Dimensiones verificadas:

- Testa: Medida mediante visión por computador.
- Altura del cono (B).
- Diámetro interior (d).
- Conicidad.
- Diámetro de pista (d1).

Datos generados:

- Gráficos de control  $\bar{X} - R$ , aunque actualmente los reportes no son muy fiables.
- Diámetro interior medido en dos posiciones específicas.

#### 4.2.5.4 ESTACIONES IBG DE CONTROL DE GRIETAS (Z3M09 y Z3M18)

Utilizan corrientes inducidas para detectar grietas o fisuras en conos y aros:

- Proceso de inspección: Variaciones en las corrientes inducidas indican irregularidades estructurales.
- Descarte de piezas: Las piezas con defectos se eliminan automáticamente.
- Datos recogidos: Variables asociadas al datamatrix activado en esta estación.

#### 4.2.5.5 ESTACIÓN LAMUCE DE MONTAJE DEL CONO (Z3M19)

Se monta el conjunto interior formado por:

- Cono, rodillos y jaula.
- Los rodillos se reciben del proveedor clasificados en familias de 2  $\mu\text{m}$  para garantizar uniformidad.
- La jaula también llega ensamblada desde el proveedor.

Control de calidad:

- Peso del conjunto: Si el peso excede los límites de tolerancia, se aparta para revisión, ya que puede indicar la falta de rodillos.
- Identificación de conos: La máquina distingue entre conos A y B y aplica tolerancias de peso correspondientes.

La homogeneidad en las dimensiones de los rodillos asegura una distribución de cargas equilibrada en el rodamiento.

#### 4.2.5.7 ESTACIÓN LAMUCE DE MEDICIÓN DE LA HOLGURA AXIAL, Z3M22

Mientras que la estación 21.1 calcula la holgura axial teórica para cada emparejamiento, esta estación mide la holgura axial real obtenida. Funciona como estación de descarte, de manera que si la holgura axial medida no se encuentra dentro de los límites tolerados (170-220  $\mu\text{m}$ ), el conjunto es retirado de la línea. Es la última estación donde el conjunto puede desmontarse fácilmente antes de agregar los elementos de unión (IRU), retenes y lubricantes. Por esta razón, es clave para la trazabilidad unitaria que se describe en el apartado 6.

#### 4.2.5.8 ESTACIÓN PARA MONTAJE DEL IRU, Z3M23

En esta estación se coloca un anillo metálico, conocido como IRU, dentro del aro, entre los dos conos. El IRU sirve como elemento de unión entre los conos.

#### **4.2.5.9 ESTACIÓN ROFIN PARA EL MARCAJE LÁSER, Z3M24**

En esta estación, se graba sobre el aro exterior un código único de 34 dígitos, tal como lo requiere el cliente.

#### **4.2.5.10 ESTACIÓN R&S DE ENGRASADO Y MONTAJE DE RETENES, Z3M25**

En esta estación se aplica la grasa necesaria para el correcto funcionamiento del rodamiento y se montan los retenes. Es la única estación en la que el producto se modifica y se verifica la operación. Esto puede ser problemático, ya que, si una pieza es incorrecta, no se puede volver a realizar la comprobación sin una nueva inyección de grasa y montaje de retenes. El proceso sigue estos pasos:

- Se pesa el conjunto y se tara la balanza.
- Se inyecta grasa en uno de los conos.
- Se pesa el conjunto después de la primera inyección para verificar si la cantidad de grasa es correcta.
- Se inyecta grasa en el segundo cono.
- Se pesa el conjunto después de la segunda inyección para verificar si la cantidad de grasa es correcta.
- Se monta el primer retén.
- Se comprueba la correcta instalación del primer retén.
- Se monta el segundo retén.
- Se comprueba la correcta instalación del segundo retén.
- Se verifica el par de giro (torque) del rodamiento una vez engrasado y con los retenes.

#### **4.2.5.11 ESTACIÓN R&S DE ACEITADO, Z3M26**

En esta estación se aplica un aceite protector para evitar el deterioro del rodamiento. No se registran datos en esta etapa.

#### **4.2.5.12 ESTACIÓN DE EMBALAJE, Z3M27**

En esta estación se escanea el código impreso del conjunto para el cliente utilizando una pistola manual, y se verifica que no sea un código repetido. Una vez confirmado que el código es único, el conjunto puede ser enviado. Este proceso es costoso y se requiere mejorar.

## ANEXO 2 DATOS SINTÉTICOS

Este anexo recoge el resto de las pruebas realizadas con los datos sintéticos

### ENTRENAMIENTO CON VARIABLES ESPURIAS

<b>1 Tree</b> Last change: Fine Tree	RMSE (Validation): 0.00018413 11/11 features
<b>2.1 Linear Regression</b> Last change: Linear	RMSE (Validation): 5.1934e-09 11/11 features
<b>2.2 Linear Regression</b> Last change: Interactions Linear	RMSE (Validation): 2.2645e-13 11/11 features
<b>2.3 Linear Regression</b> Last change: Robust Linear	RMSE (Validation): 5.2165e-09 11/11 features
<b>2.4 Stepwise Linear Regression</b> Last change: Stepwise Linear	RMSE (Validation): 5.2809e-09 11/11 features
<b>2.5 Tree</b> Last change: Fine Tree	RMSE (Validation): 0.00018413 11/11 features
<b>2.6 Tree</b>	RMSE (Validation): 0.00022175

**Model 2.2: Linear Regression**  
Status: Trained

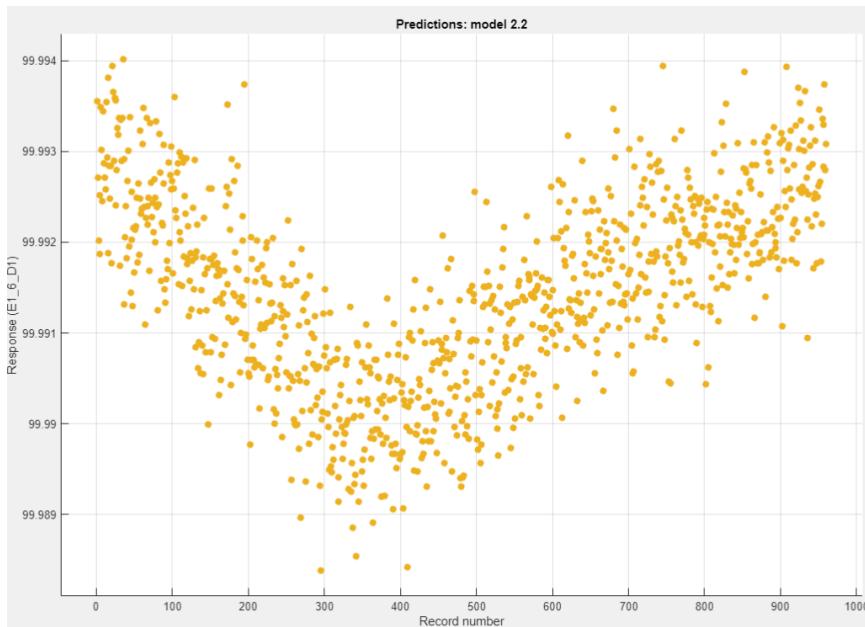
**Training Results**

RMSE (Validation)	2.2645e-13
R-Squared (Validation)	1.00
MSE (Validation)	5.1279e-26
MAE (Validation)	1.6778e-13
MAPE (Validation)	0.0%
Prediction speed	~6000 obs/sec
Training time	13.588 sec
Model size (Compact)	~97 kB

**Model Hyperparameters**

- Feature Selection: 11/11 individual features selected
- PCA: Disabled
- Optimizer: Not applicable

**TABLA 12 MODELOS DE ENTRENAMIENTO Y TEST DE DATOS SINTÉTICOS**



**ILUSTRACIÓN 82 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICIONES**

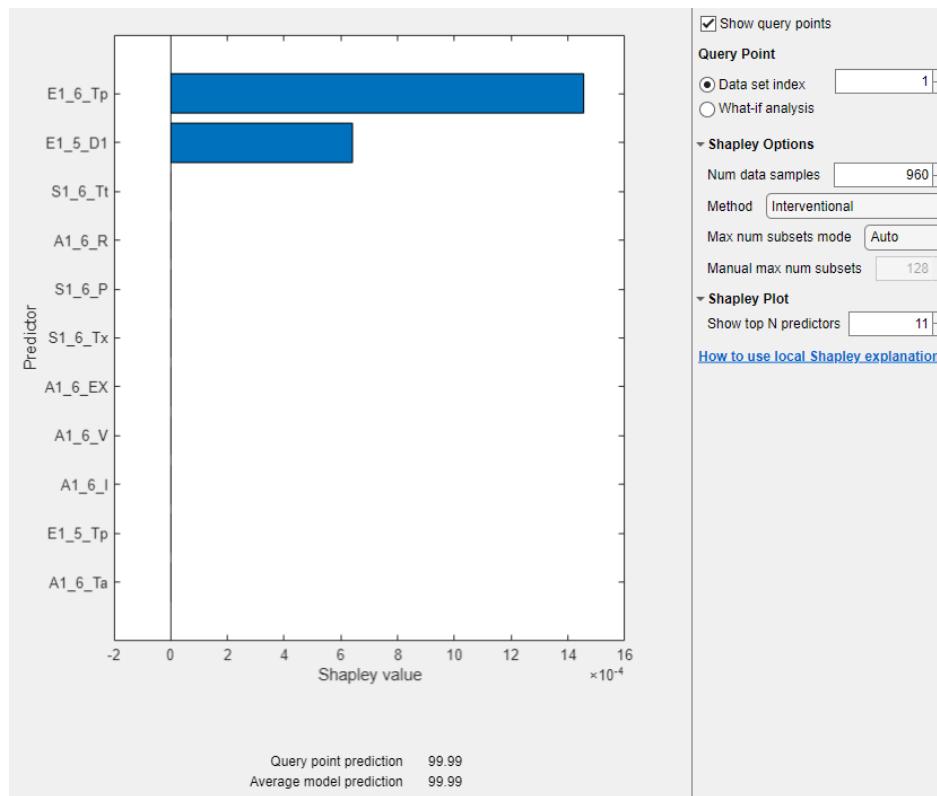


ILUSTRACIÓN 83 GRÁFICA SHAPLEY INTERVENCIONAL

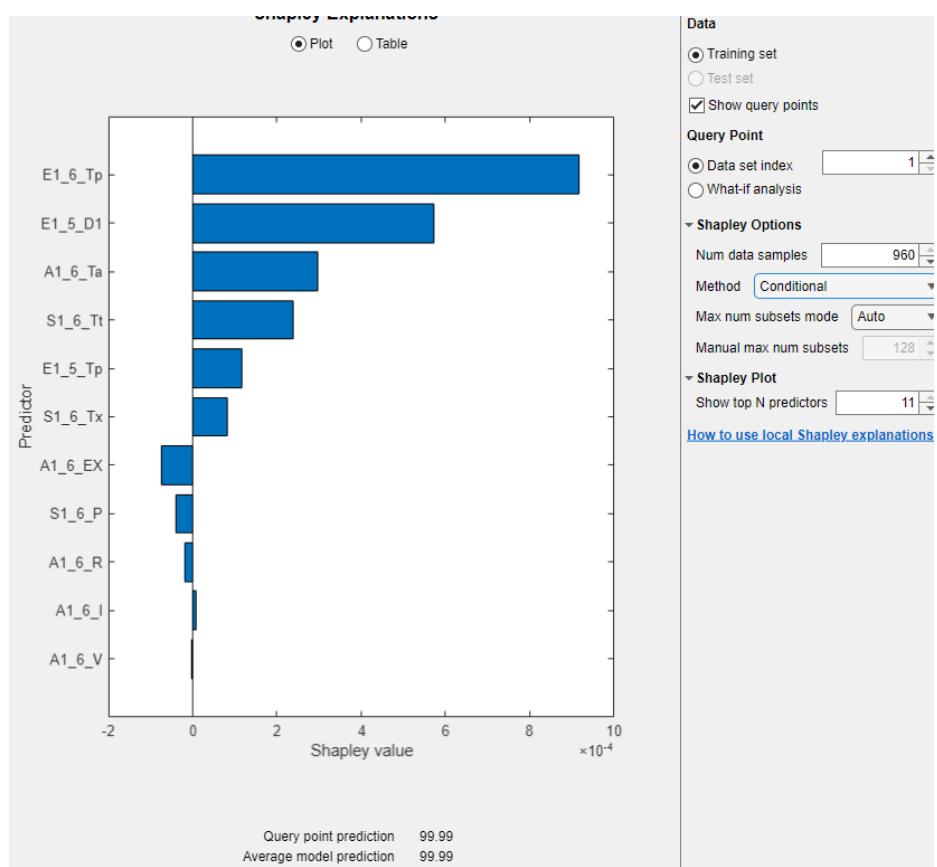


ILUSTRACIÓN 84 GRÁFICA SHAPLEY CONDICIONAL

## FACTOR RUIDO = 3.8 (SOLO CON RUIDO)

1 Tree	RMSE (Validation): 0.00020484
Last change: Fine Tree	2/2 features
2.1 Linear Regression	RMSE (Validation): 0.00010855
Last change: Linear	2/2 features
2.2 Linear Regression	RMSE (Validation): 0.00010864
Last change: Interactions Linear	2/2 features
2.3 Linear Regression	RMSE (Validation): 0.00010856
Last change: Robust Linear	2/2 features
2.4 Stepwise Linear Regr...	RMSE (Validation): 0.00010855
Last change: Stepwise Linear	2/2 features
2.5 Tree	RMSE (Validation): 0.00020484
Last change: Fine Tree	2/2 features

**Model 2.1: Linear Regression**  
Status: Trained

**Training Results**

RMSE (Validation)	0.00010855
R-Squared (Validation)	0.99
MSE (Validation)	1.1784e-08
MAE (Validation)	8.6182e-05
MAPE (Validation)	0.0%
Prediction speed	~75000 obs/sec
Training time	1.9667 sec
Model size (Compact)	~4 kB

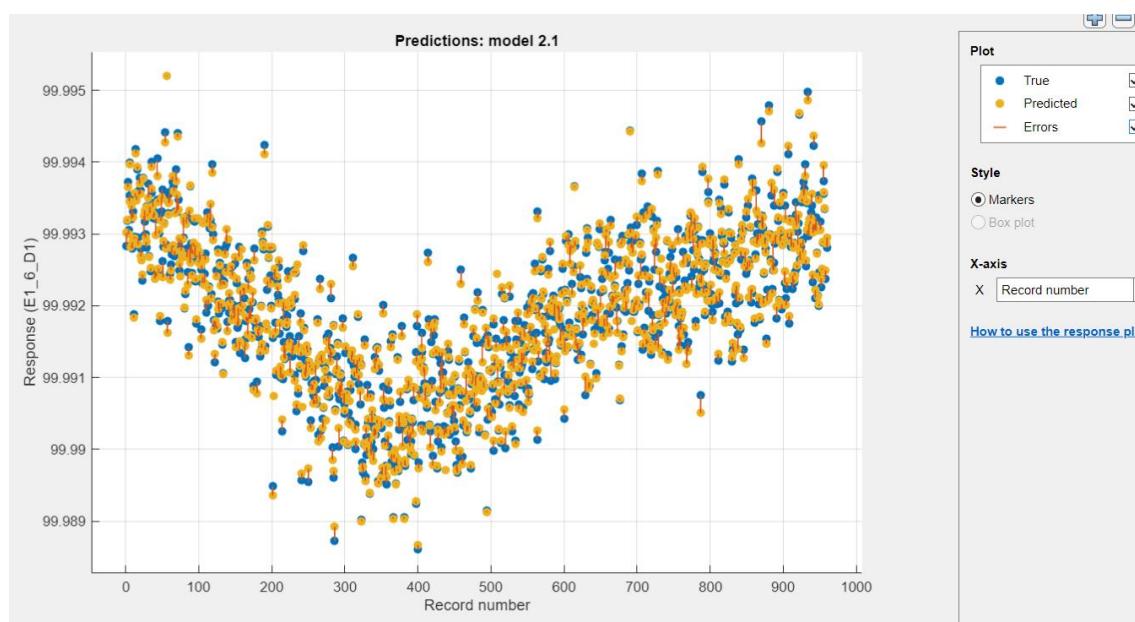
► **Model Hyperparameters**

► **Feature Selection: 2/2 individual features selected**

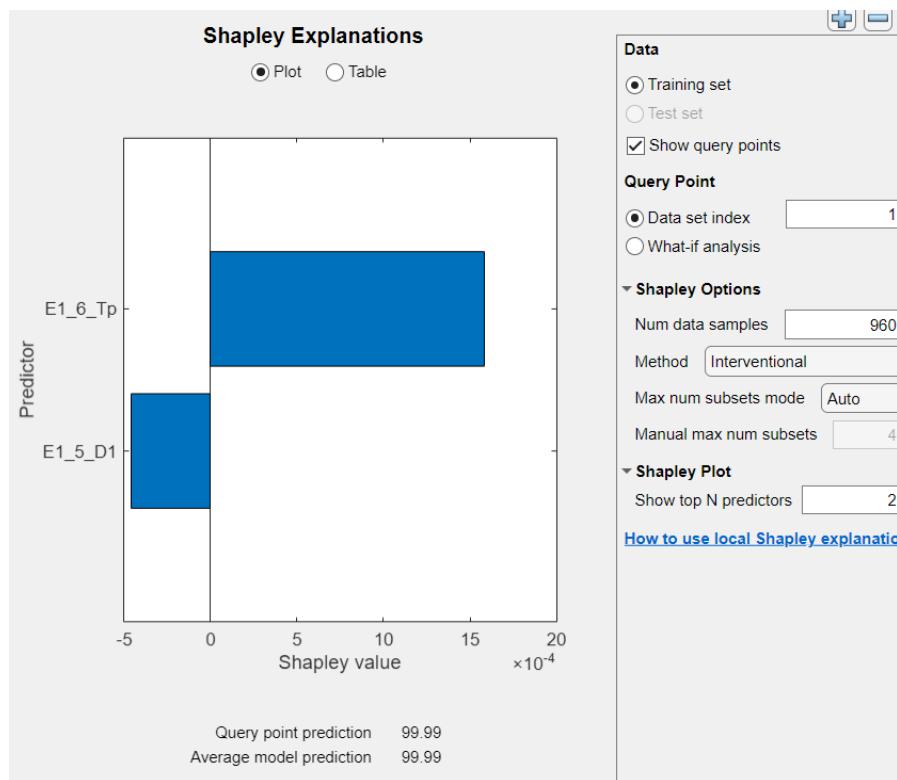
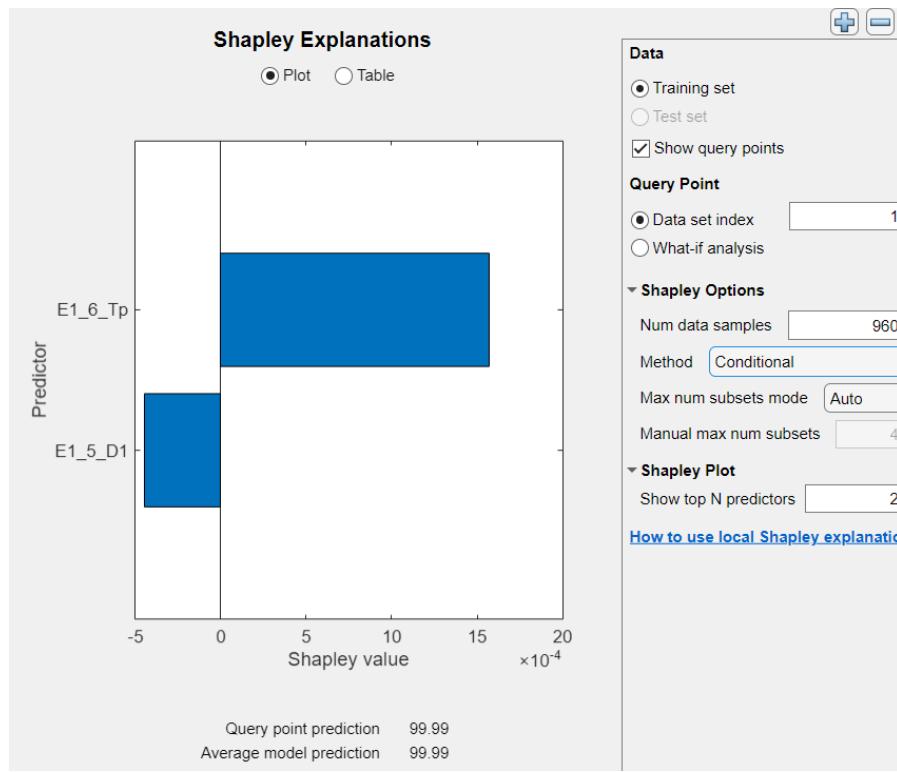
► **PCA: Disabled**

► **Optimizer: Not applicable**

**TABLA 13 MODELOS DE ENTRENAMIENTO Y TEST DE DATOS SINTÉTICOS**



**ILUSTRACIÓN 85 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICCIONES**

**ILUSTRACIÓN 86 GRÁFICA SHAPLEY INTERVENCIONAL****ILUSTRACIÓN 87 GRÁFICA SHAPLEY CONDICIONAL**

## FACTOR RUIDO = 4.7 (SOLO CON RUIDO)

2.17 Ensemble	RMSE (Validation): 0.00018455
Last change: Bagged Trees	2/2 features
2.18 Gaussian Process R...	RMSE (Validation): 0.00013412
Last change: Squared Exponential GPR	2/2 features
2.19 Gaussian Process R...	RMSE (Validation): 0.00013413
Last change: Matern 5/2 GPR	2/2 features
2.20 Gaussian Process R...	RMSE (Validation): 0.00015707
Last change: Exponential GPR	2/2 features
2.21 Gaussian Process R...	RMSE (Validation): 0.00013412
Last change: Rational Quadratic GPR	2/2 features
2.22 Neural Network	RMSE (Validation): 0.012227
Last change: Narrow Neural Network	2/2 features

**Model 2.21: Gaussian Process Regression**  
Status: Trained

**Training Results**

RMSE (Validation)	0.00013412
R-Squared (Validation)	0.98
MSE (Validation)	1.7987e-08
MAE (Validation)	0.00010625
MAPE (Validation)	0.0%
Prediction speed	~13000 obs/sec
Training time	46.417 sec
Model size (Compact)	~32 kB

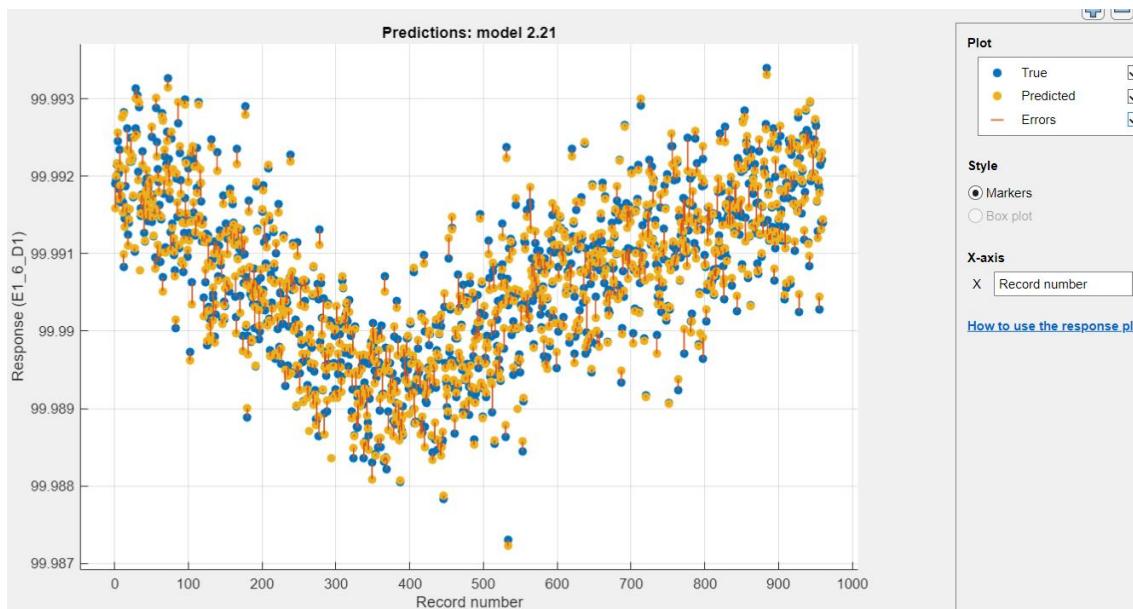
► **Model Hyperparameters**

► **Feature Selection:** 2/2 individual features selected

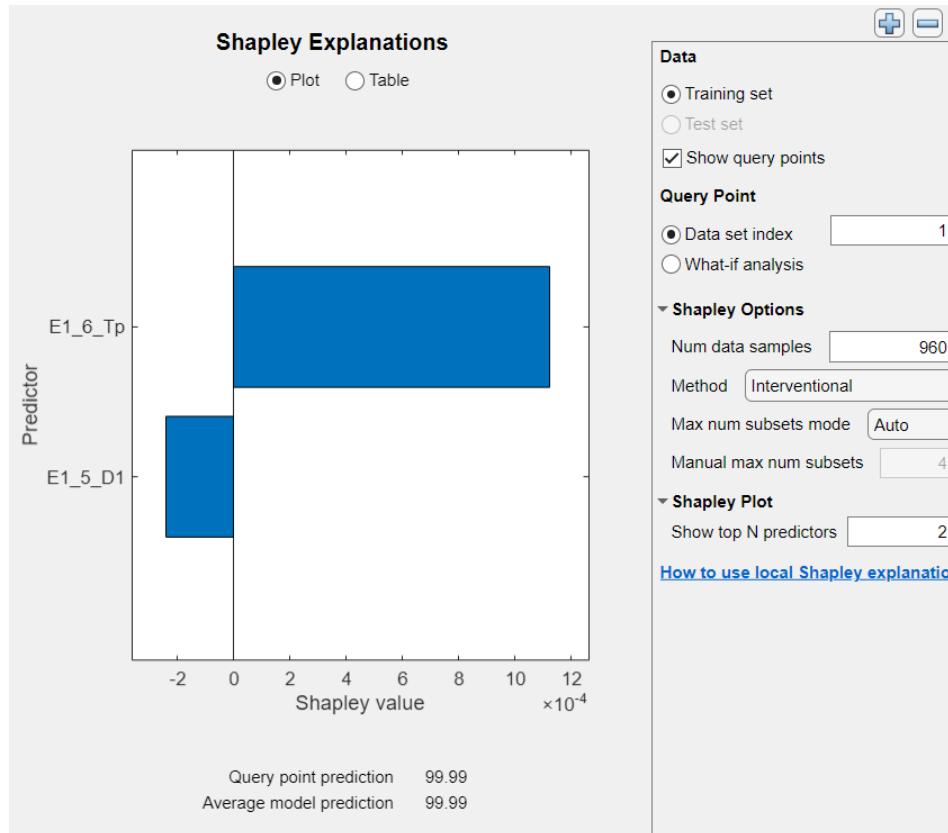
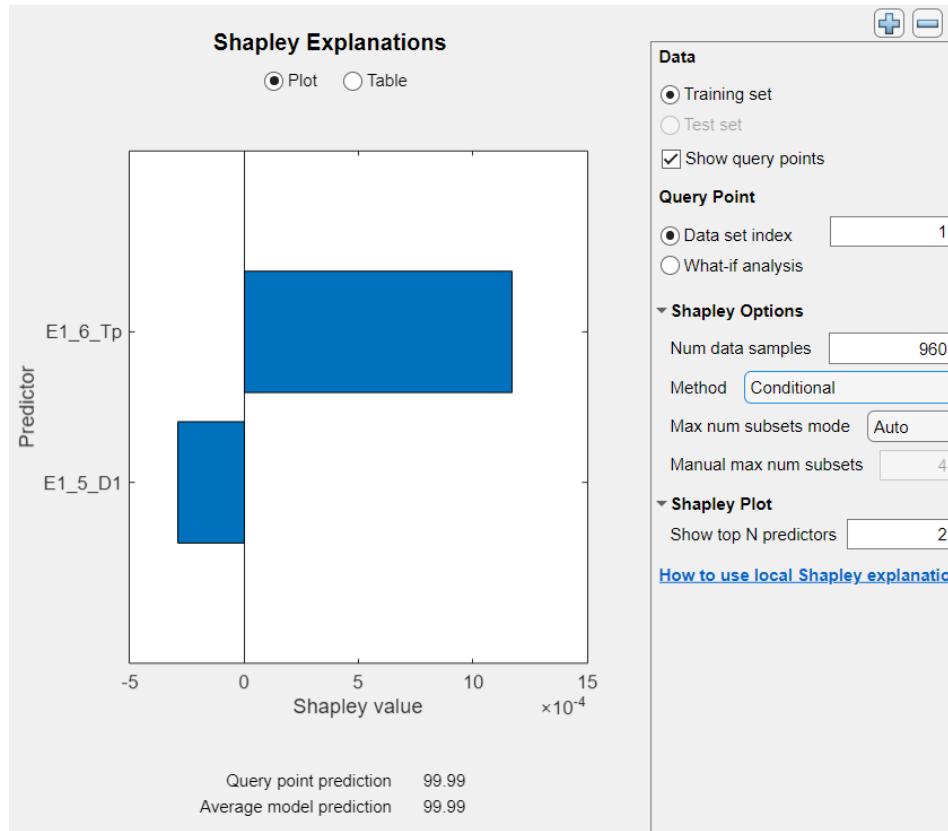
► **PCA:** Disabled

► **Optimizer:** Not applicable

**TABLA 14 MODELOS DE ENTRENAMIENTO Y TEST DE DATOS SINTÉTICOS**



**ILUSTRACIÓN 88 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICCIONES**

**ILUSTRACIÓN 89 GRÁFICA SHAPLEY INTERVENCIONAL****ILUSTRACIÓN 90 GRÁFICA SHAPLEY CONDICIONAL**

## FACTOR RUIDO = 7.5 (SOLO CON RUIDO)

1 Tree	RMSE (Validation): 0.00029591
Last change: Fine Tree	2/2 features
2.1 Linear Regression	RMSE (Validation): 0.00021440
Last change: Linear	2/2 features
2.2 Linear Regression	RMSE (Validation): 0.00021453
Last change: Interactions Linear	2/2 features
2.3 Linear Regression	RMSE (Validation): 0.00021443
Last change: Robust Linear	2/2 features
2.4 Stepwise Linear Regr...	RMSE (Validation): 0.00021440
Last change: Stepwise Linear	2/2 features
2.5 Tree	RMSE (Validation): 0.00029591
Last change: Fine Tree	2/2 features

**Model 2.1: Linear Regression**  
Status: Trained

**Training Results**

RMSE (Validation)	0.00021440
R-Squared (Validation)	0.96
MSE (Validation)	4.5969e-08
MAE (Validation)	0.00017188
MAPE (Validation)	0.0%
Prediction speed	~28000 obs/sec
Training time	5.4172 sec
Model size (Compact)	~4 kB

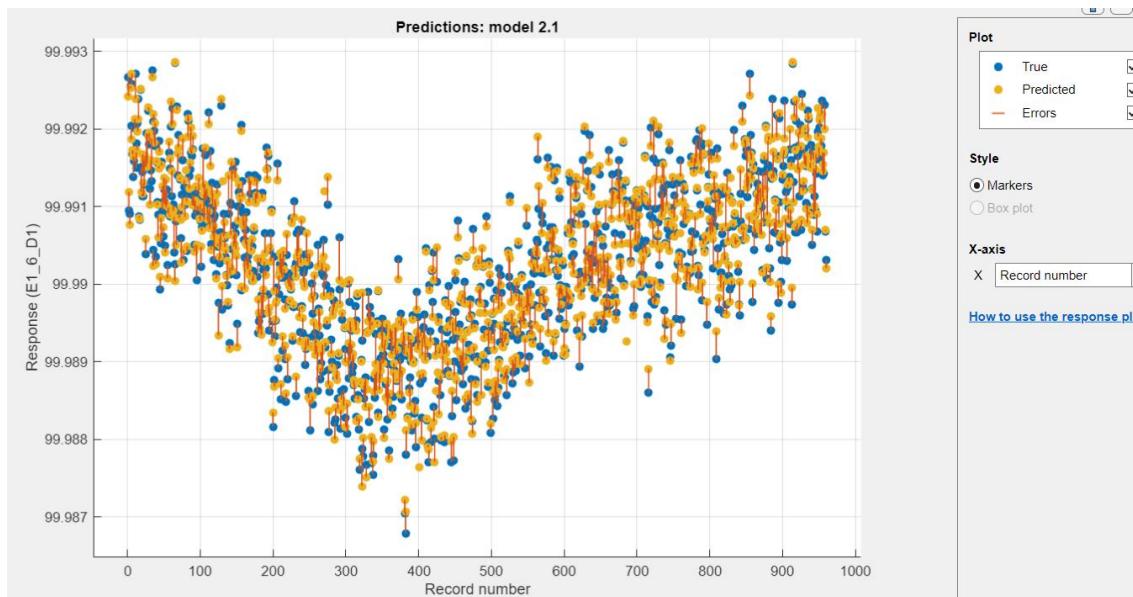
► Model Hyperparameters

► Feature Selection: 2/2 individual features selected

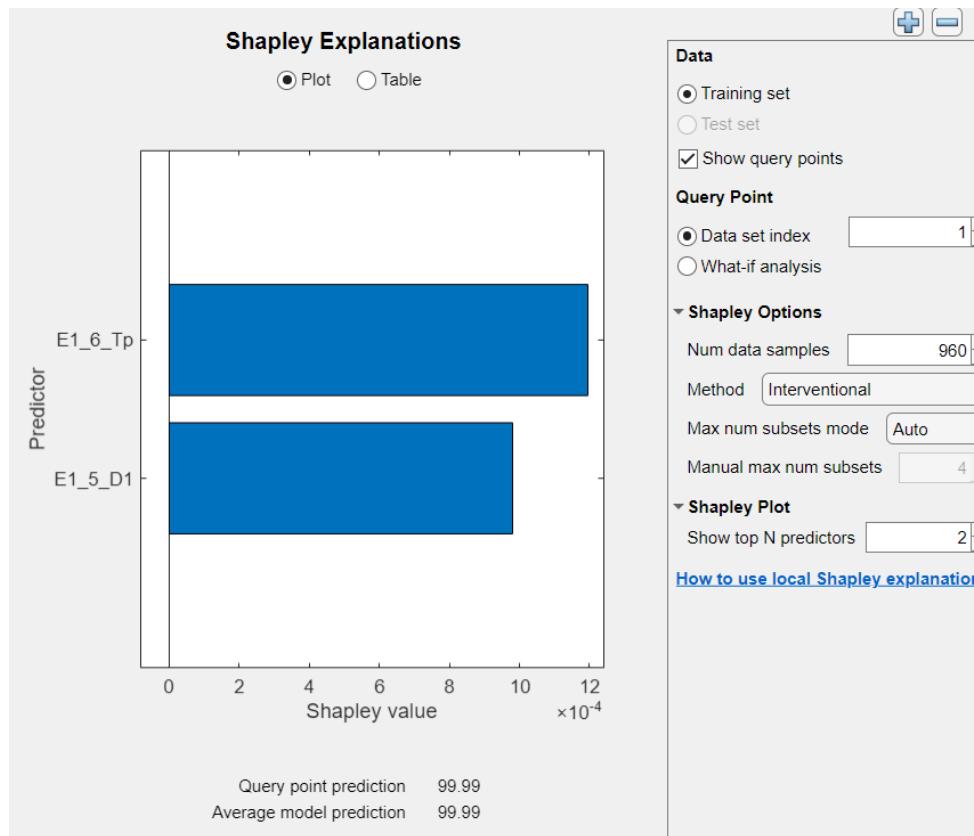
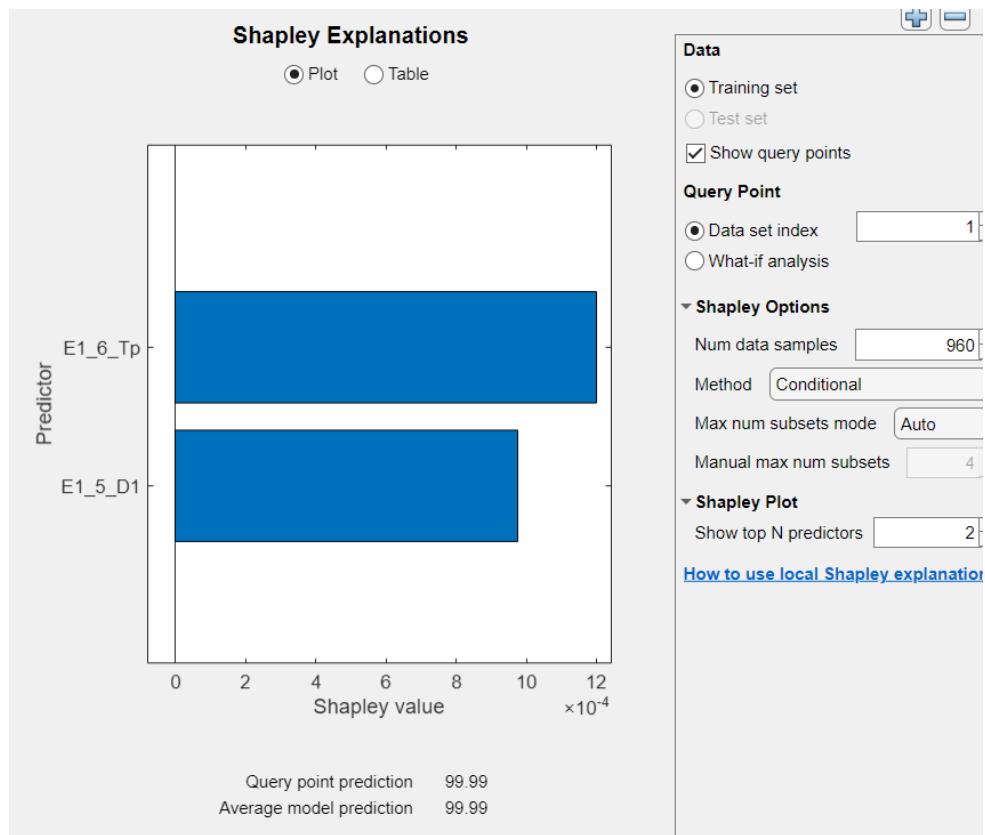
► PCA: Disabled

► Optimizer: Not applicable

**TABLA 15 MODELOS DE ENTRENAMIENTO Y TEST DE DATOS SINTÉTICOS**



**ILUSTRACIÓN 91 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICCIONES**

**ILUSTRACIÓN 92 GRÁFICA SHAPLEY INTERVENCIONAL****ILUSTRACIÓN 93 GRÁFICA SHAPLEY CONDICIONAL**

## FACTOR RUIDO = 3.8 (CON RUIDO Y VARIABLES ESPURIAS)

1 Tree	RMSE (Validation): 0.00021500
Last change: Fine Tree	11/11 features
2.1 Linear Regression	RMSE (Validation): 0.00010526
Last change: Linear	11/11 features
2.2 Linear Regression	RMSE (Validation): 0.00010776
Last change: Interactions Linear	11/11 features
2.3 Linear Regression	RMSE (Validation): 0.00010529
Last change: Robust Linear	11/11 features
2.4 Stepwise Linear Regr...	RMSE (Validation): 0.00010627
Last change: Stepwise Linear	11/11 features
2.5 Tree	RMSE (Validation): 0.00021500
Last change: Fine Tree	11/11 features

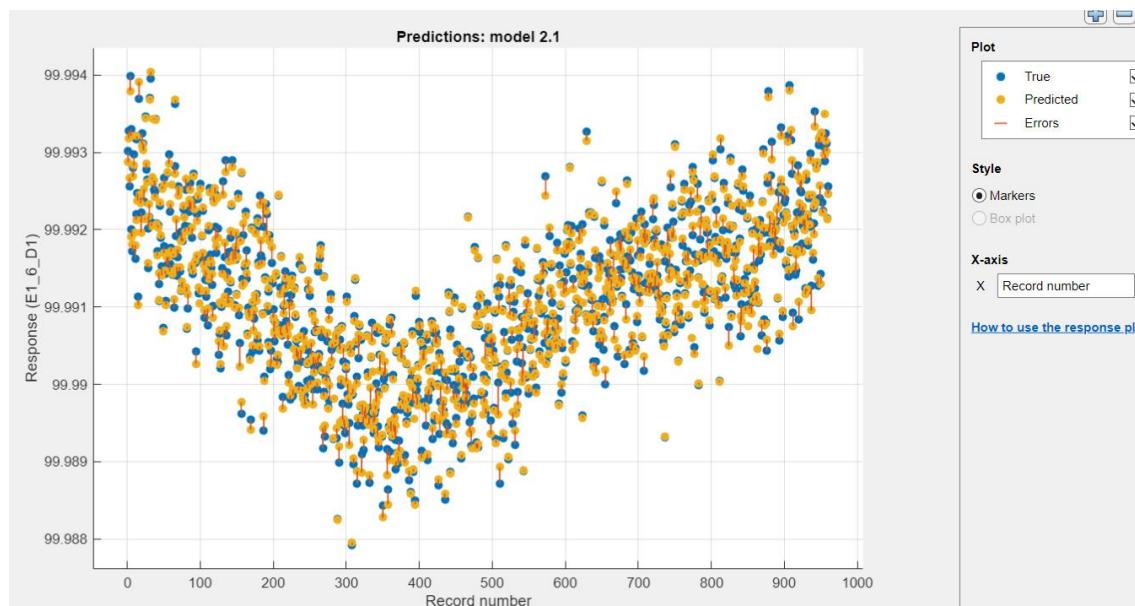
**Model 2.1: Linear Regression**  
Status: Trained

**Training Results**

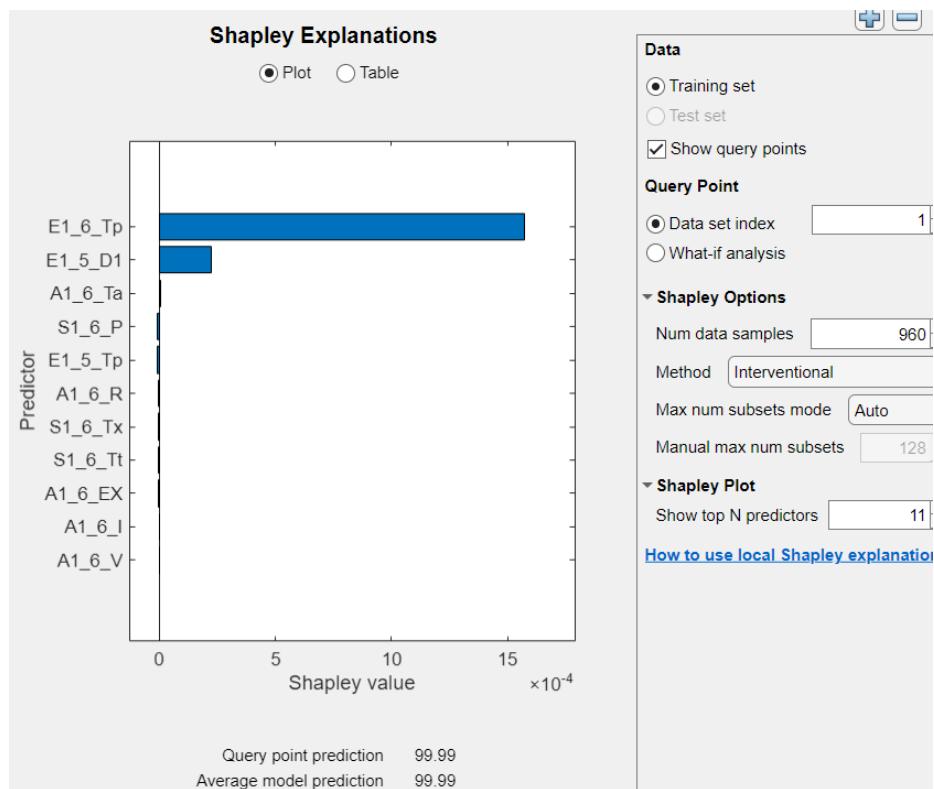
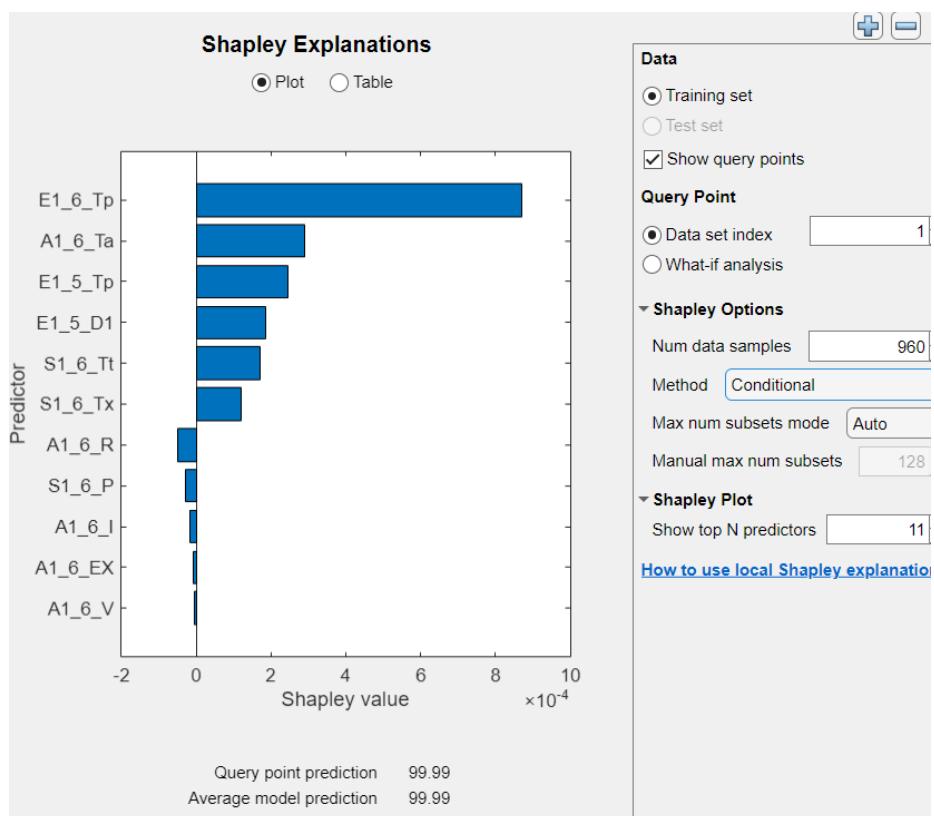
RMSE (Validation)	0.00010526
R-Squared (Validation)	0.99
MSE (Validation)	1.1081e-08
MAE (Validation)	8.2806e-05
MAPE (Validation)	0.0%
Prediction speed	~4200 obs/sec
Training time	11.167 sec
Model size (Compact)	~13 kB

► **Model Hyperparameters**  
 ► **Feature Selection: 11/11 individual features selected**  
 ► **PCA: Disabled**  
 ► **Optimizer: Not applicable**

**TABLA 16 MODELOS DE ENTRENAMIENTO Y TEST DE DATOS SINTÉTICOS**



**ILUSTRACIÓN 94 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICIONES**

**ILUSTRACIÓN 95 GRÁFICA SHAPLEY INTERVENCIONAL****ILUSTRACIÓN 96 GRÁFICA SHAPLEY CONDICIONAL**

## FACTOR RUIDO = 4.7 (CON RUIDO Y VARIABLES ESPURIAS)

Sort by Model Number ▾

1 Tree	RMSE (Validation): 0.00025834
Last change: Fine Tree	11/11 features
2.1 Linear Regression	RMSE (Validation): 0.00013730
Last change: Linear	11/11 features
2.2 Linear Regression	RMSE (Validation): 0.00014410
Last change: Interactions Linear	11/11 features
2.3 Linear Regression	RMSE (Validation): 0.00013727
Last change: Robust Linear	11/11 features
2.4 Stepwise Linear Regr...	RMSE (Validation): 0.00013684
Last change: Stepwise Linear	11/11 features
2.5 Tree	RMSE (Validation): 0.00025834
Last change: Fine Tree	11/11 features

Summary X Response Plot X

**Model 2.4: Stepwise Linear Regression**  
Status: Trained

**Training Results**

RMSE (Validation)	0.00013684
R-Squared (Validation)	0.98
MSE (Validation)	1.8726e-08
MAE (Validation)	0.00010755
MAPE (Validation)	0.0%
Prediction speed	~27000 obs/sec
Training time	36.048 sec
Model size (Compact)	~9 kB

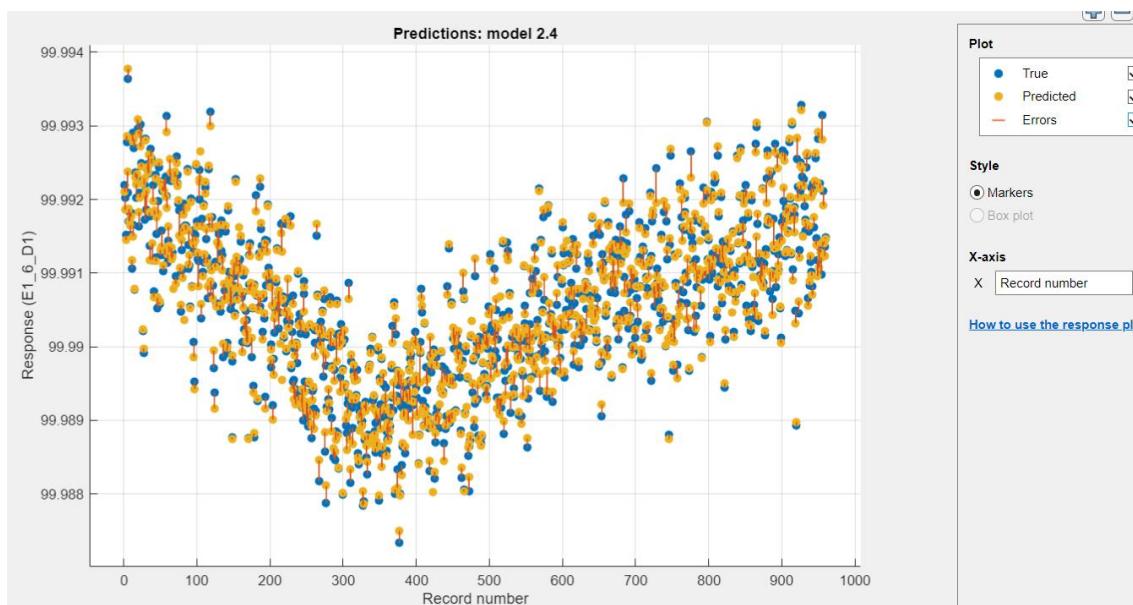
► Model Hyperparameters

► Feature Selection: 11/11 individual features selected

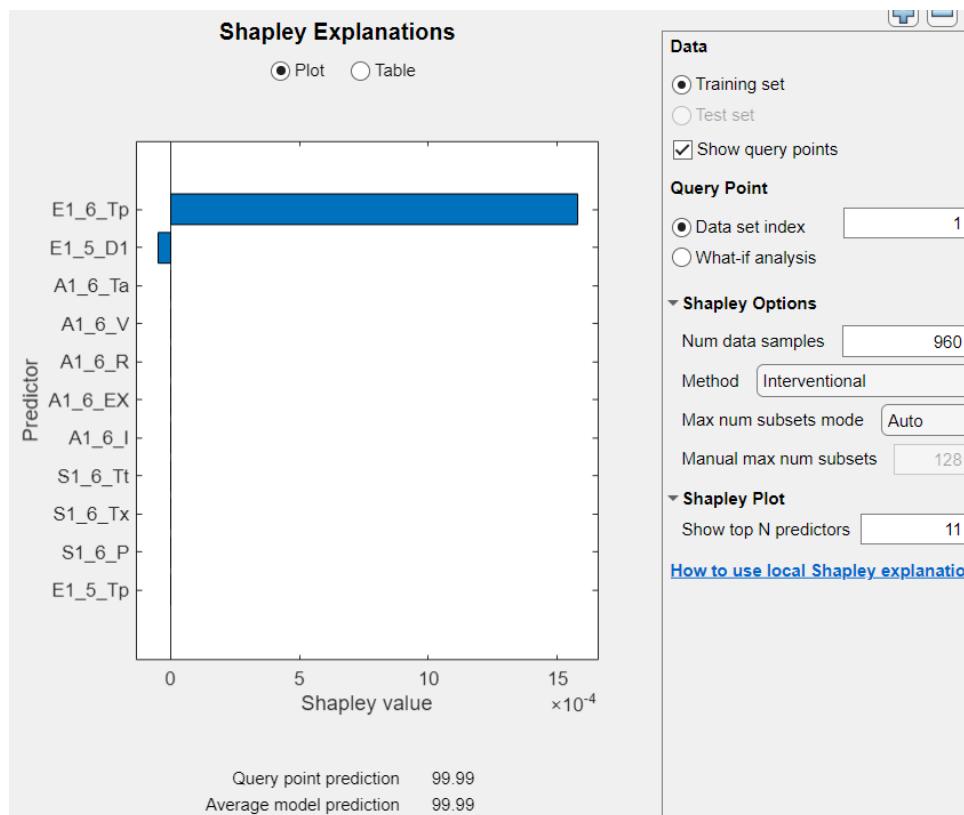
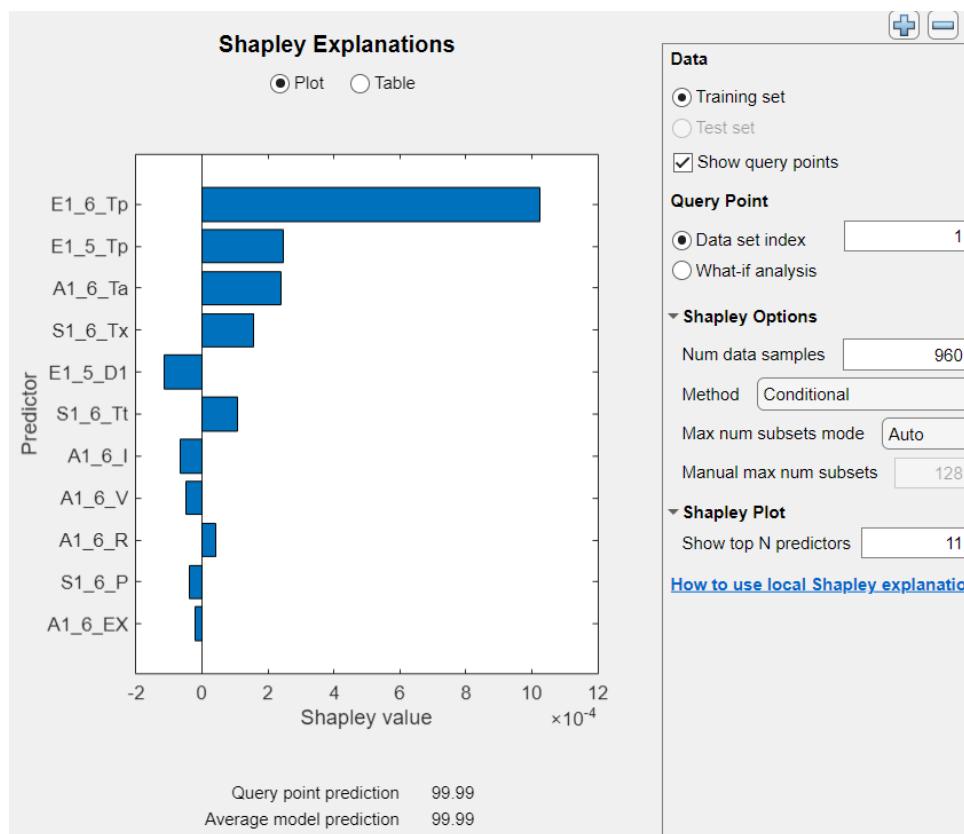
► PCA: Disabled

► Optimizer: Not applicable

**TABLA 17 MODELOS DE ENTRENAMIENTO Y TEST DE DATOS SINTÉTICOS**



**ILUSTRACIÓN 97 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICCIONES**

**ILUSTRACIÓN 98 GRÁFICA SHAPLEY INTERVENCIONAL****ILUSTRACIÓN 99 GRÁFICA SHAPLEY CONDICIONAL**

## FACTOR RUIDO = 7.5 (CON RUIDO Y VARIABLES ESPURIAS)

1 Tree	RMSE (Validation): 0.00033113
Last change: Fine Tree	11/11 features
2.1 Linear Regression	RMSE (Validation): 0.00021447
Last change: Linear	11/11 features
2.2 Linear Regression	RMSE (Validation): 0.00022147
Last change: Interactions Linear	11/11 features
2.3 Linear Regression	RMSE (Validation): 0.00021460
Last change: Robust Linear	11/11 features
2.4 Stepwise Linear Regr...	RMSE (Validation): 0.00021601
Last change: Stepwise Linear	11/11 features
2.5 Tree	RMSE (Validation): 0.00033113
Last change: Fine Tree	11/11 features

**Model 2.1:** Linear Regression  
Status: Trained

**Training Results**

RMSE (Validation)	0.00021447
R-Squared (Validation)	0.96
MSE (Validation)	4.5998e-08
MAE (Validation)	0.00017233
MAPE (Validation)	0.0%
Prediction speed	~21000 obs/sec
Training time	5.6024 sec
Model size (Compact)	~13 kB

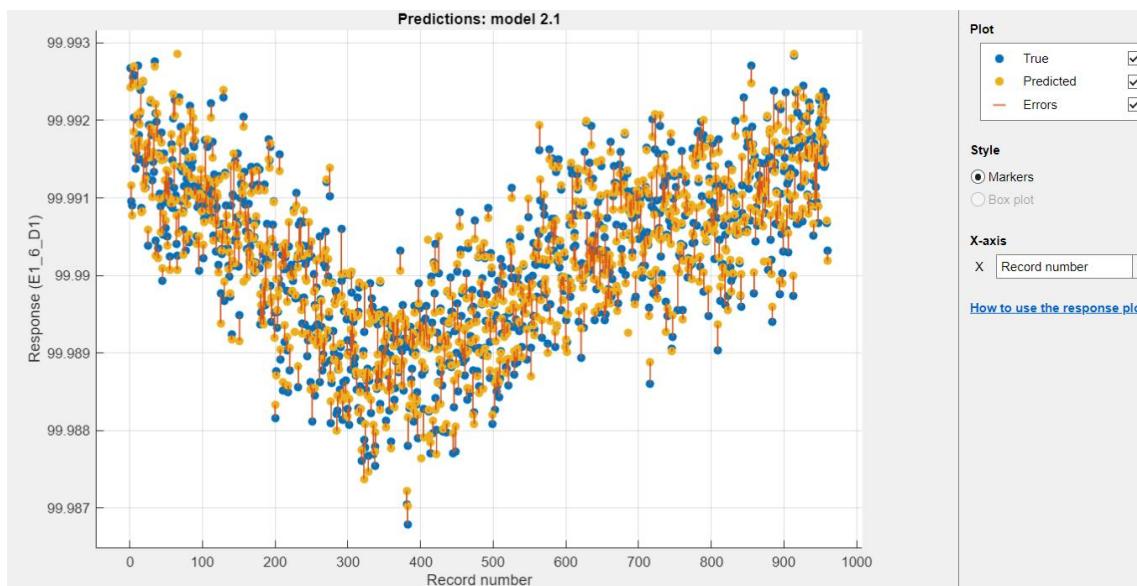
► **Model Hyperparameters**

► **Feature Selection:** 11/11 individual features selected

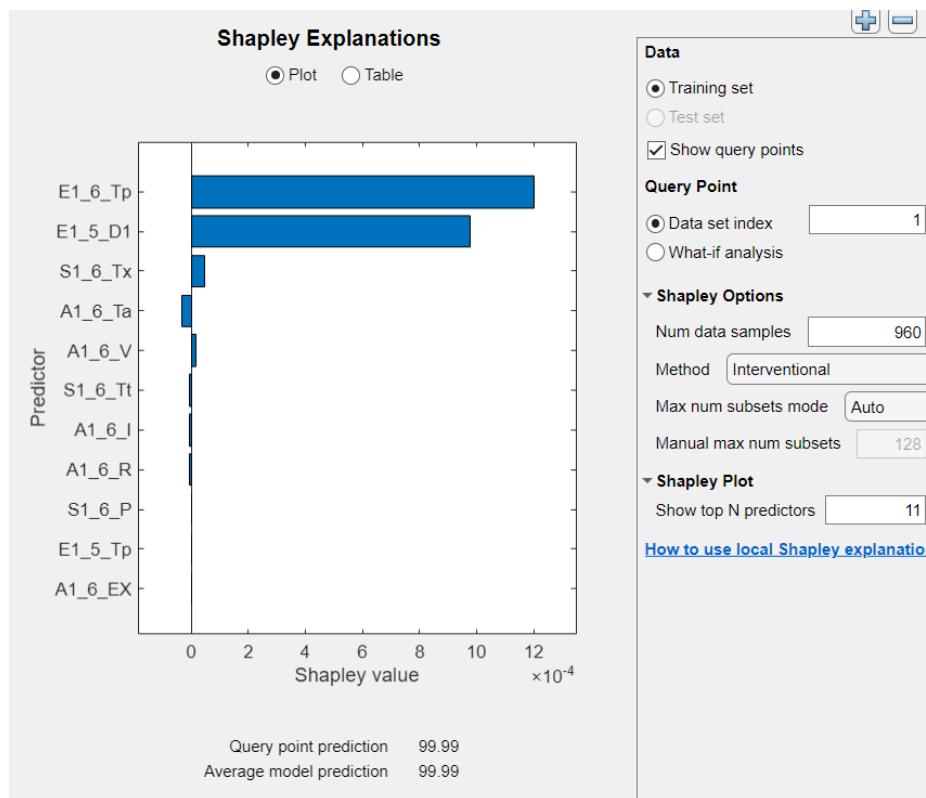
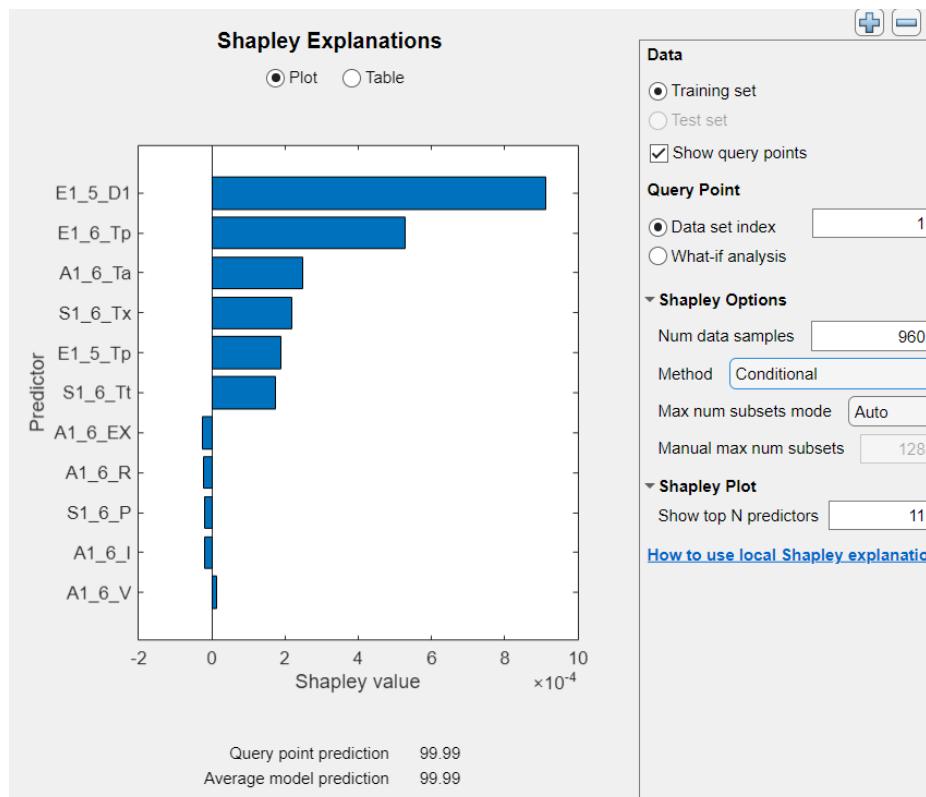
► **PCA:** Disabled

► **Optimizer:** Not applicable

**TABLA 18 MODELOS DE ENTRENAMIENTO Y TEST DE DATOS SINTÉTICOS**



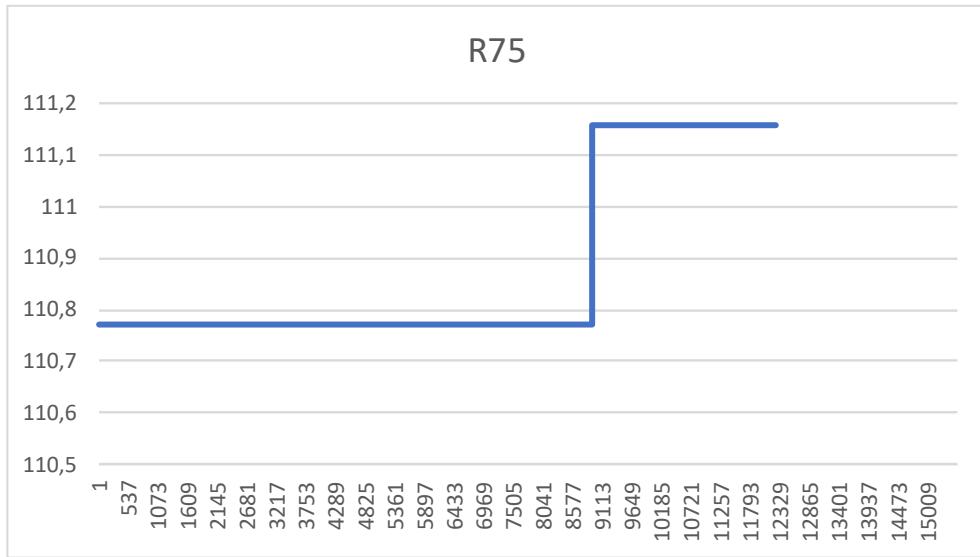
**ILUSTRACIÓN 100 GRÁFICA COMPARATIVA DE LA RESPUESTA REAL OBTENIDA FRENTE A LAS PREDICCIONES**

**ILUSTRACIÓN 101 GRÁFICA SHAPLEY INTERVENCIONAL****ILUSTRACIÓN 102 GRÁFICA SHAPLEY CONDICIONAL**

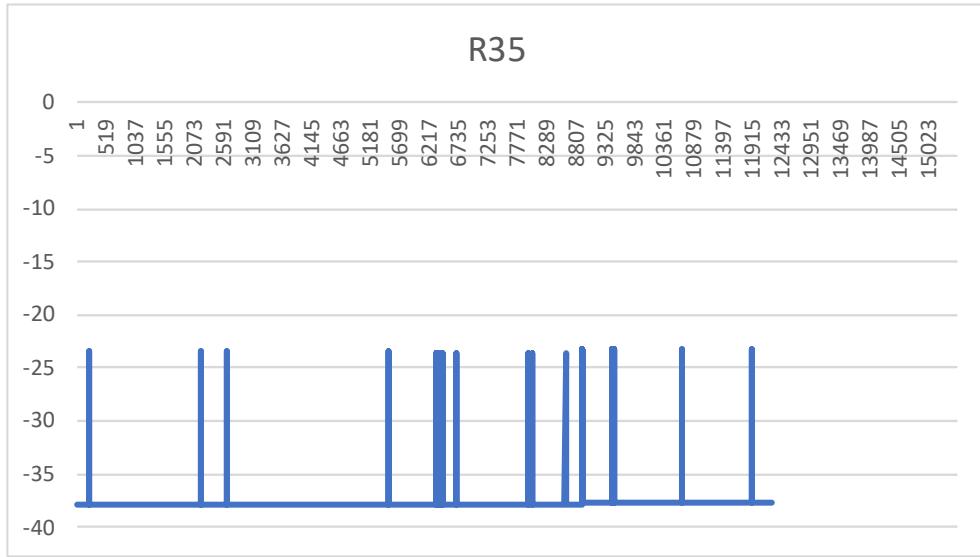
## ANEXO 3 CONOS

En este anexo se procede de la misma forma que se ha hecho con los conos A pero esta vez con los conos B:

### CONOS B



**ILUSTRACIÓN 103 GRÁFICA DEL COMPORTAMIENTO DE LA POSICIÓN FIN DE TRABAJO Z**



**ILUSTRACIÓN 104 GRÁFICA DEL COMPORTAMIENTO DE LA POSICIÓN FIN DE TRABAJO X**

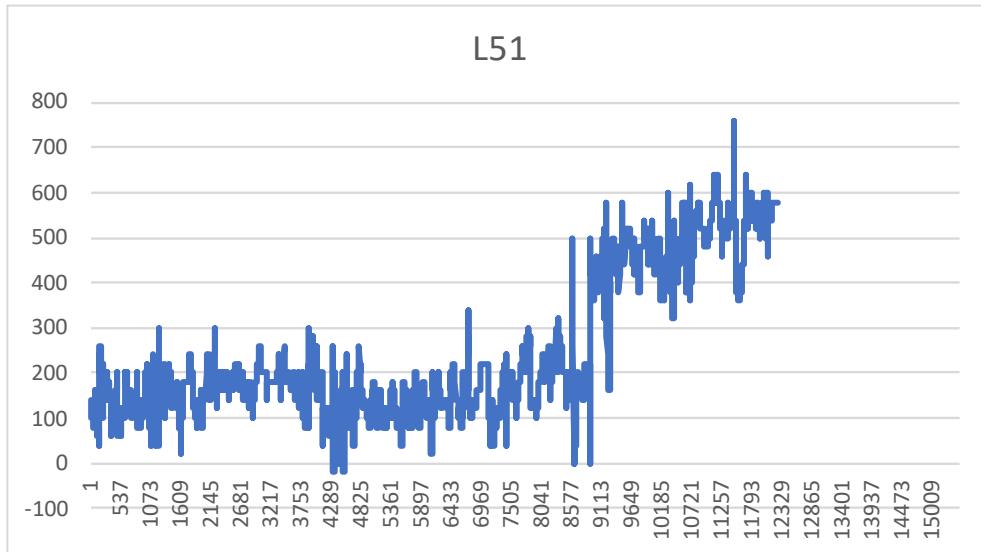


ILUSTRACIÓN 105 GRÁFICA DEL COMPORTAMIENTO DE LA SUMA DE CORRECCIONES EJE X

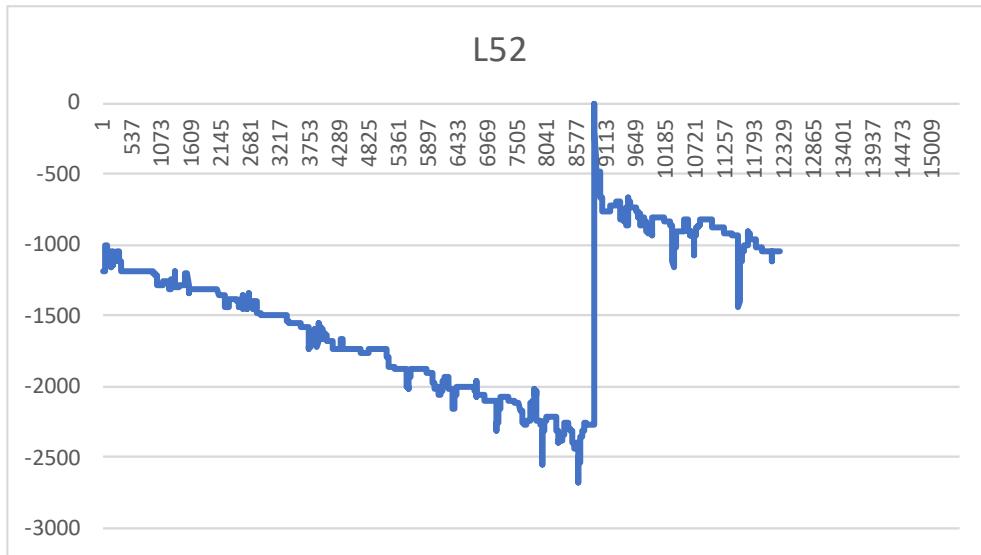
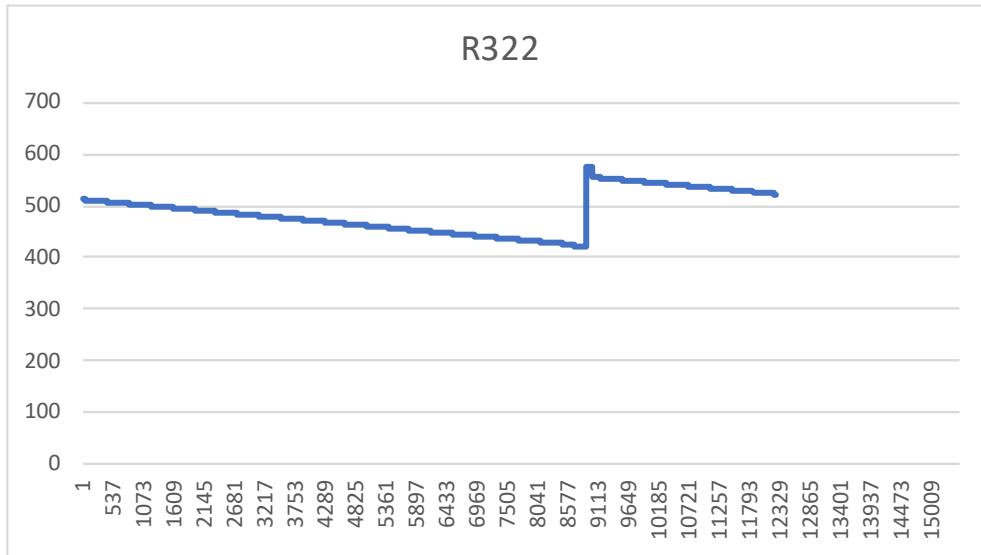


ILUSTRACIÓN 106 GRÁFICA DEL COMPORTAMIENTO DE LA SUMA DE CORRECCIONES EJE Z



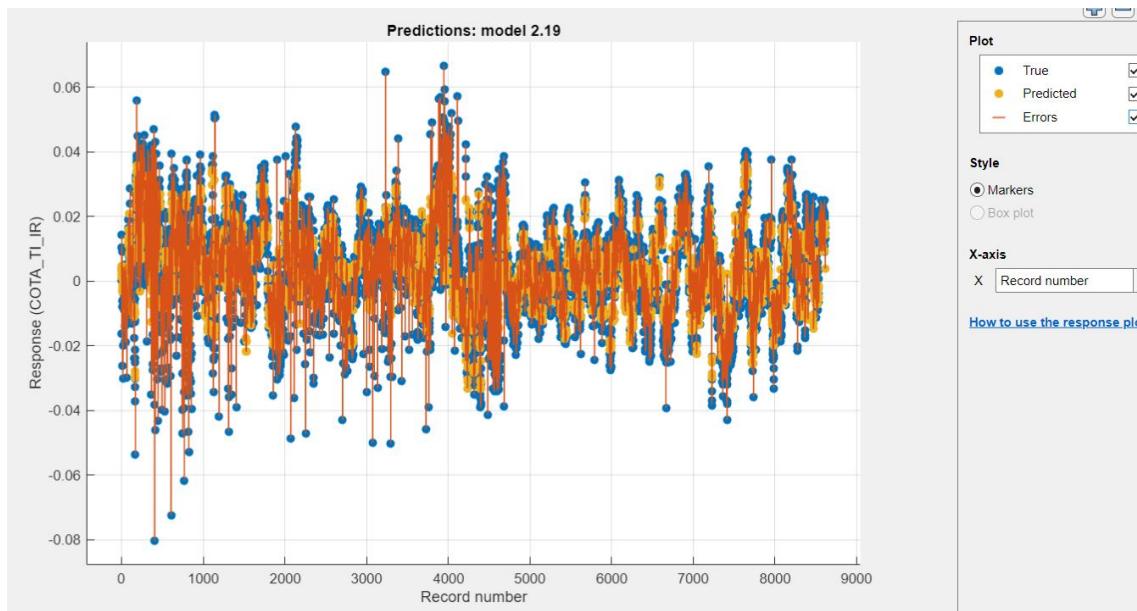
**ILUSTRACIÓN 107 GRÁFICA DEL COMPORTAMIENTO DEL DIÁMETRO ACTUAL DE MUELA**

## ENTRENAMIENTO Y TEST POR CONOS

### ENTRENAMIENTO CONO A1 Y TEST CONO A2

<b>2.17</b> Ensemble	RMSE (Test): 0.037190	<b>Model 2.19</b> : Gaussian Process Regression Status: Tested
Last change: Bagged Trees	5/5 features	
<b>2.18</b> Gaussian Process Regression	RMSE (Test): 0.014378	
Last change: Squared Exponential GPR	5/5 features	
<b>2.19</b> Gaussian Process Regression	RMSE (Test): 0.014248	
Last change: Matern 5/2 GPR	5/5 features	
<b>2.20</b> Gaussian Process Regression	RMSE (Test): 0.020759	
Last change: Exponential GPR	5/5 features	
<b>2.21</b> Gaussian Process Re...	RMSE (Validation): <b>0.0083277</b>	
Last change: Rational Quadratic GPR	5/5 features	
<b>2.22</b> Neural Network	RMSE (Test): 3.3211e+10	<b>Training Results</b> RMSE (Validation): 0.0086692 R-Squared (Validation): 0.64 MSE (Validation): 7.5154e-05 MAE (Validation): 0.0058129 MAPE (Validation): 1131.3% Prediction speed: ~2900 obs/sec Training time: 372.79 sec Model size (Compact): ~422 kB
Last change: Narrow Neural Network	5/5 features	
<b>2.23</b> Neural Network	RMSE (Test): 5.2447e+10	<b>Test Results</b> RMSE (Test): 0.014248 R-Squared (Test): -0.14 MSE (Test): 0.00020299 MAE (Test): 0.010596 MAPE (Test): 287.2%
Last change: Medium Neural Network	5/5 features	
<b>2.24</b> Neural Network	RMSE (Test): 2.0795e+10	<b>Model Hyperparameters</b> Preset: Matern 5/2 GPR Basis function: Constant Kernel function: Matern 5/2 Use isotropic kernel: Yes Kernel scale: Automatic Signal standard deviation: Automatic Sigma: Automatic Standardize data: Yes Optimize numeric parameters: Yes
Last change: Wide Neural Network	5/5 features	
<b>2.25</b> Neural Network	RMSE (Test): 3.8206e+10	<b>Feature Selection:</b> 5/5 individual features selected
Last change: Bilayered Neural Network	5/5 features	
<b>2.26</b> Neural Network	RMSE (Test): 7.3367e+09	<b>PCA:</b> Disabled
Last change: Trilayered Neural Network	5/5 features	
<b>2.27</b> Kernel	RMSE (Validation): 0.0096372	<b>Optimizer:</b> Not applicable
Last change: SVM Kernel	5/5 features	

**TABLA 19 MODELOS DE ENTRENAMIENTO DE LOS CONOS**

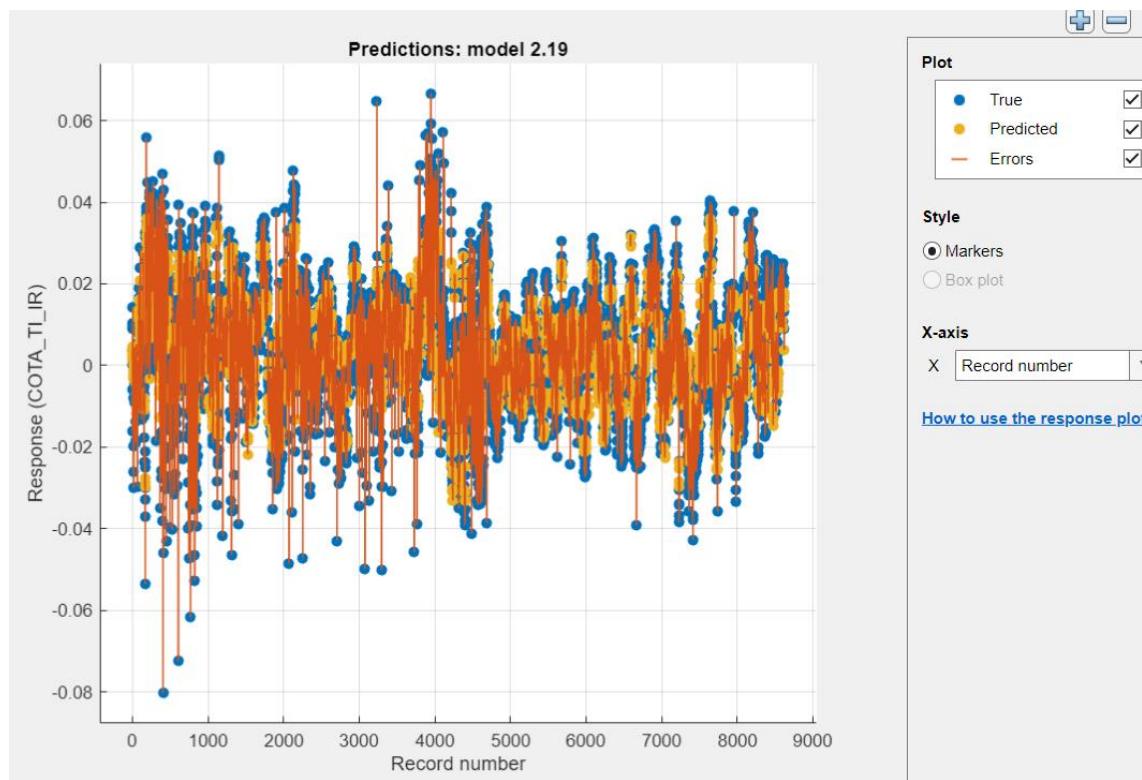


**ILUSTRACIÓN 108 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

### ENTRENAMIENTO CONO A1 Y TEST CONO B2

<b>2.17</b> Ensemble	RMSE (Test): 0.035018	Last change: Bagged Trees	5/5 features	<b>Model 2.19</b> : Gaussian Process Regression
				Status: Tested
<b>2.18</b> Gaussian Process Regression	RMSE (Test): 0.014398	Last change: Squared Exponential GPR	5/5 features	<b>Training Results</b>
				RMSE (Validation) 0.0086692
<b>2.19</b> Gaussian Process Regression	RMSE (Test): 0.014341	Last change: Matern 5/2 GPR	5/5 features	R-Squared (Validation) 0.64
				MSE (Validation) 7.5154e-05
<b>2.20</b> Gaussian Process Regression	RMSE (Test): 0.020203	Last change: Exponential GPR	5/5 features	MAE (Validation) 0.0058129
				MAPE (Validation) 1131.3%
<b>2.21</b> Gaussian Process Regression	RMSE (Test): <b>0.021804</b>	Last change: Rational Quadratic GPR	5/5 features	Prediction speed ~2900 obs/sec
				Training time 372.79 sec
<b>2.22</b> Neural Network	RMSE (Test): 1.3065e+11	Last change: Narrow Neural Network	5/5 features	Model size (Compact) ~422 kB
<b>2.23</b> Neural Network	RMSE (Test): 1.9827e+11	Last change: Medium Neural Network	5/5 features	<b>Test Results</b>
				RMSE (Test) 0.014341
<b>2.24</b> Neural Network	RMSE (Test): 4.9793e+10	Last change: Wide Neural Network	5/5 features	R-Squared (Test) -0.04
				MSE (Test) 0.00020565

**TABLA 20 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 109 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## ENTRENAMIENTO CONO B1 Y TEST CONO B2

Model 2.17 Ensemble RMSE (Test): 0.035795  
Last change: Bagged Trees 5/5 features

Model 2.18 Gaussian Pr... RMSE (Test): 0.015376  
Last change: Squared Exponential GPR 5/5 feature

Model 2.19 Gaussian Pr... RMSE (Test): 0.015271  
Last change: Matern 5/2 GPR 5/5 features

Model 2.20 Gaussian Pr... RMSE (Test): 0.019246  
Last change: Exponential GPR 5/5 features

Model 2.21 Gaussian Pr... RMSE (Test): **0.023062**  
Last change: Rational Quadratic GPR 5/5 features

Model 2.22 Neural Net... RMSE (Test): 1.0460e+10  
Last change: Narrow Neural Network 5/5 features

Model 2.23 Neural Net... RMSE (Test): 9.7396e+09  
Last change: Medium Neural Network 5/5 features

Model 2.24 Neural Net... RMSE (Test): 7.8830e+09  
Last change: Wide Neural Network 5/5 features

Model 2.25 Neural Net... RMSE (Test): 6.7712e+09  
Last change: Bilayered Neural Network 5/5 features

Model 2.26 Neural Net... RMSE (Test): 1.1206e+09  
Last change: Trilayered Neural Network 5/5 feature

Model 2.27 Kernel RMSE (Test): 0.049976  
Last change: SVM Kernel 5/5 features

**Model 2.19: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.0083577
R-Squared (Validation)	0.67
MSE (Validation)	6.9851e-05
MAE (Validation)	0.0058024
MAPE (Validation)	235.0%
Prediction speed	~3300 obs/sec
Training time	396.27 sec
Model size (Compact)	~423 kB

**Test Results**

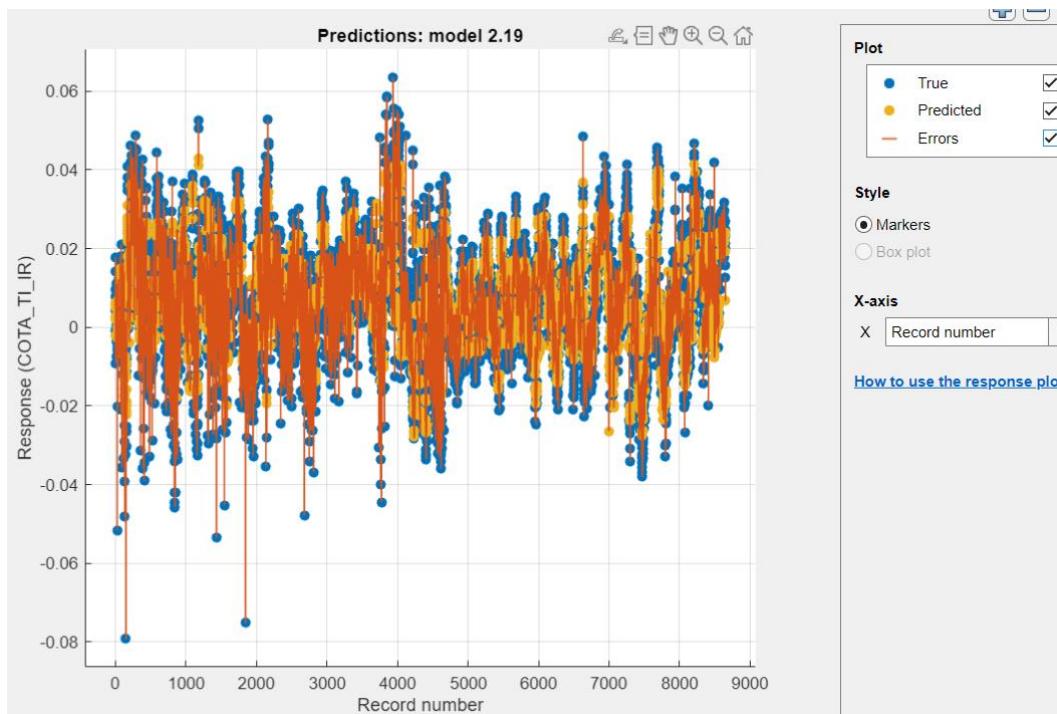
RMSE (Test)	0.015271
R-Squared (Test)	-0.18
MSE (Test)	0.00023320
MAE (Test)	0.011144
MAPE (Test)	480.4%

**Model Hyperparameters**

Preset: Matern 5/2 GPR  
Basis function: Constant  
Kernel function: Matern 5/2  
Use isotropic kernel: Yes  
Kernel scale: Automatic  
Signal standard deviation: Automatic  
Sigma: Automatic  
Standardize data: Yes  
Optimize numeric parameters: Yes

► Feature Selection: 5/5 individual features selected  
► PCA: Disabled  
► Optimizer: Not applicable

**TABLA 21 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 110 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## ENTRENAMIENTO CONO A1 Y TEST CONO A2

2.17 Ensemble	RMSE (Test): 0.037948
Last change: Bagged Trees	5/5 features
2.18 Gaussian Process Regression	RMSE (Test): 0.015852
Last change: Squared Exponential GPR	5/5 features
2.19 Gaussian Process Regression	RMSE (Test): 0.015709
Last change: Matern 5/2 GPR	5/5 features
2.20 Gaussian Process Regression	RMSE (Test): 0.019808
Last change: Exponential GPR	5/5 features
2.21 Gaussian Process Regression	RMSE (Test): <b>0.024587</b>
Last change: Rational Quadratic GPR	5/5 features
2.22 Neural Network	RMSE (Test): 1.0460e+10
Last change: Narrow Neural Network	5/5 features
2.23 Neural Network	RMSE (Test): 9.7395e+09
Last change: Medium Neural Network	5/5 features
2.24 Neural Network	RMSE (Test): 7.8830e+09
Last change: Wide Neural Network	5/5 features
2.25 Neural Network	RMSE (Test): 6.7712e+09
Last change: Bilayered Neural Network	5/5 features

**Model 2.19: Gaussian Process Regression**  
Status: Tested

**Training Results**

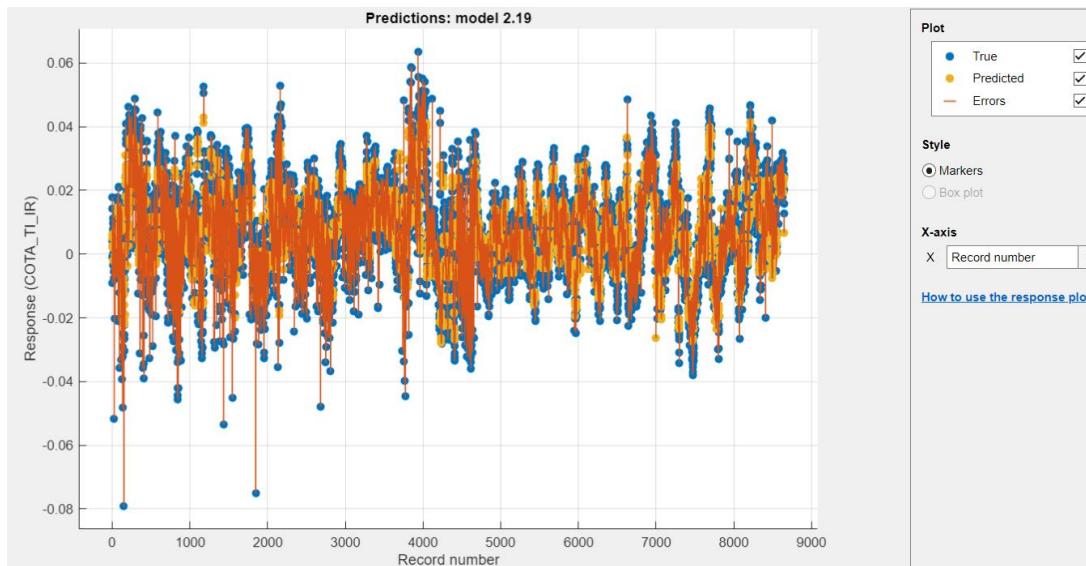
RMSE (Validation)	0.0083577
R-Squared (Validation)	0.67
MSE (Validation)	6.9851e-05
MAE (Validation)	0.0058024
MAPE (Validation)	235.0%
Prediction speed	~3300 obs/sec
Training time	396.27 sec
Model size (Compact)	~423 kB

**Test Results**

RMSE (Test)	0.015709
R-Squared (Test)	-0.39
MSE (Test)	0.00024676
MAE (Test)	0.011929
MAPE (Test)	450.0%

► **Model Hyperparameters**  
 ► **Feature Selection: 5/5 individual features selected**  
 ► **PCA: Disabled**  
 ► **Optimizer: Not applicable**

**TABLA 22 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



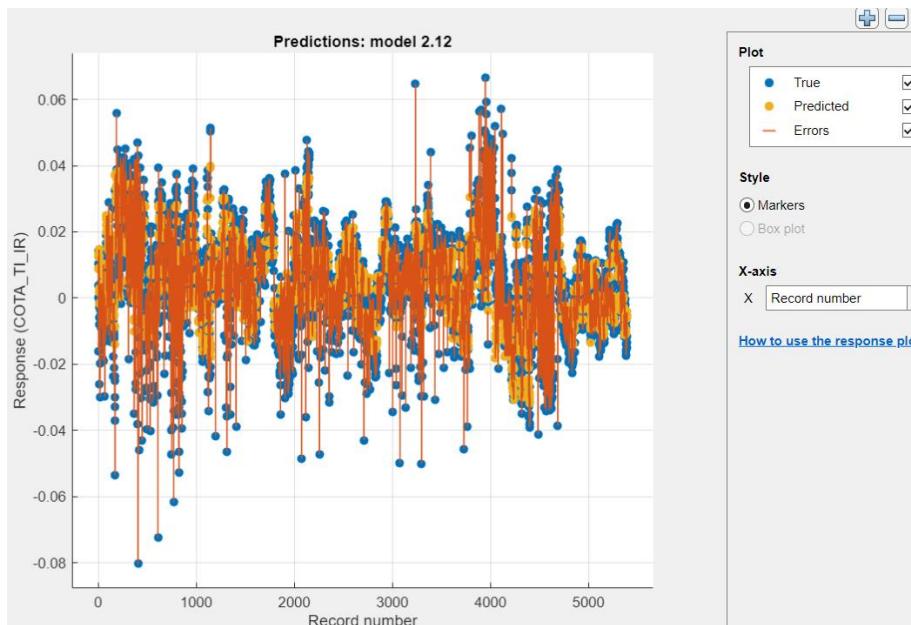
**ILUSTRACIÓN 111 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## ENTRENAMIENTO Y TEST POR SEMANAS

### CONO A: ENTRENAMIENTO DEL DÍA 2 AL 9 Y TEST DEL 10 AL 16

2.11 SVM	RMSE (Test): 0.013304	Model 2.12: SVM
Last change: Fine Gaussian SVM	5/5 features	Status: Tested
2.12 SVM	RMSE (Test): 0.010680	<b>Training Results</b>
Last change: Medium Gaussian SVM	5/5 features	RMSE (Validation) 0.010171 R-Squared (Validation) 0.54 MSE (Validation) 0.00010345 MAE (Validation) 0.0066259 MAPE (Validation) 196.1% Prediction speed ~30000 obs/sec Training time 14.014 sec Model size (Compact) ~212 kB
2.13 SVM	RMSE (Test): 0.024504	<b>Test Results</b>
Last change: Coarse Gaussian SVM	5/5 features	RMSE (Test) 0.010680 R-Squared (Test) 0.37 MSE (Test) 0.00011406 MAE (Test) 0.0084275 MAPE (Test) 851.5%
2.14 Efficient Linear	RMSE (Test): 0.012840	<b>Model Hyperparameters</b>
Last change: Efficient Linear Least Squares	5/5 fea	Preset: Medium Gaussian SVM Kernel function: Gaussian Kernel scale: 2.2 Box constraint: Automatic Epsilon: Auto Standardize data: Yes
2.15 Efficient Linear	RMSE (Test): 0.013509	<b>Feature Selection:</b> 5/5 individual features selected
Last change: Efficient Linear SVM	5/5 features	<b>PCA:</b> Disabled
2.16 Ensemble	RMSE (Test): 0.012611	<b>Optimizer:</b> Not applicable
Last change: Boosted Trees	5/5 features	
2.17 Ensemble	RMSE (Test): 0.013391	
Last change: Bagged Trees	5/5 features	
2.18 Gaussian Pr...	RMSE (Test): 0.015952	
Last change: Squared Exponential GPR	5/5 feature	
2.19 Gaussian Pr...	RMSE (Test): 0.014084	
Last change: Matern 5/2 GPR	5/5 features	
2.20 Gaussian Pr...	RMSE (Test): 0.012105	
Last change: Exponential GPR	5/5 features	
2.21 Gaussian Pr...	RMSE (Test): 0.011293	
Last change: Rational Quadratic GPR	5/5 features	

**TABLA 23 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 112 GRÁFICA COMPARATIVA DE LAS PREDICIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## CONO A: ENTRENAMIENTO DEL DÍA 2 AL 9 Y TEST DEL 19 AL 24

Sort by Model Number ▾

Last change: Fine Gaussian SVM 5/5 features

2.12 SVM	RMSE (Test): 0.013355
Last change: Medium Gaussian SVM	5/5 features
2.13 SVM	RMSE (Test): 0.062271
Last change: Coarse Gaussian SVM	5/5 features
2.14 Efficient Linear	RMSE (Test): 0.073072
Last change: Efficient Linear Least Squares	5/5 features
2.15 Efficient Linear	RMSE (Test): 0.014454
Last change: Efficient Linear SVM	5/5 features
2.16 Ensemble	RMSE (Test): 0.034438
Last change: Boosted Trees	5/5 features
2.17 Ensemble	RMSE (Test): 0.038769
Last change: Bagged Trees	5/5 features
2.18 Gaussian Process Regression	RMSE (Test): 0.014489
Last change: Squared Exponential GPR	5/5 features
2.19 Gaussian Process Regression	RMSE (Test): 0.016104
Last change: Matern 5/2 GPR	5/5 features
2.20 Gaussian Process Regression	RMSE (Test): 0.035040
Last change: Exponential GPR	5/5 features
2.21 Gaussian Process Re...	RMSE (Validation): 0.0096921
Last change: Rational Quadratic GPR	5/5 features

Model 2.12: SVM

Status: Tested

**Training Results**

RMSE (Validation): 0.010189  
 R-Squared (Validation): 0.53  
 MSE (Validation): 0.00010381  
 MAE (Validation): 0.0066386  
 MAPE (Validation): 193.4%  
 Prediction speed: ~28000 obs/sec  
 Training time: 10.721 sec  
 Model size (Compact): ~212 kB

**Test Results**

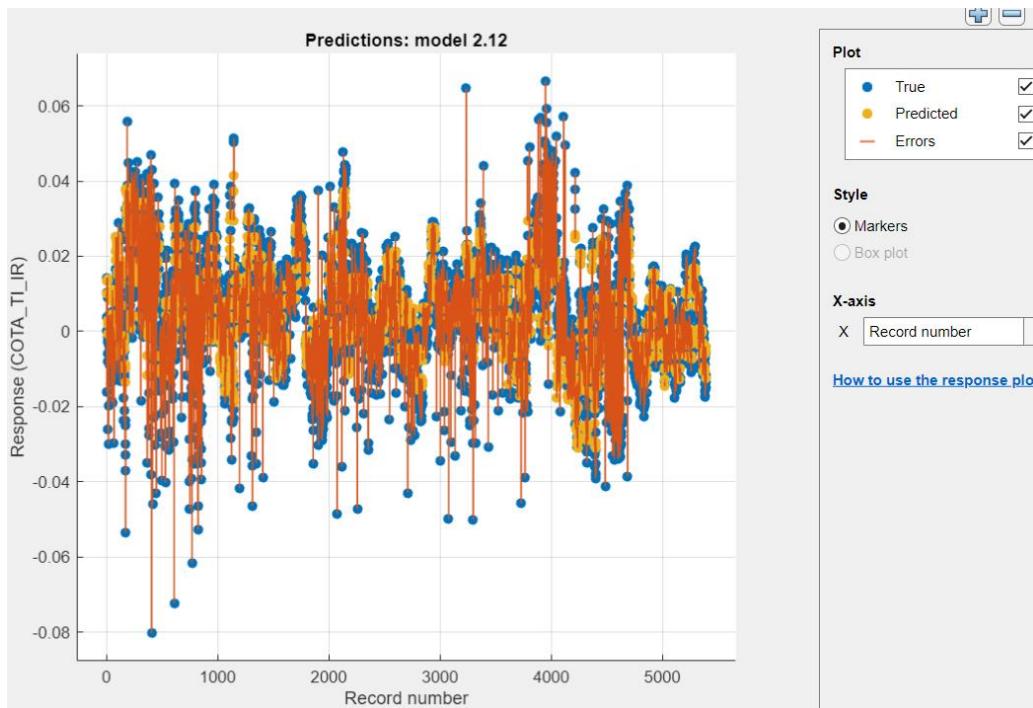
RMSE (Test): 0.013355  
 R-Squared (Test): -0.00  
 MSE (Test): 0.00017835  
 MAE (Test): 0.010022  
 MAPE (Test): 104.7%

**Model Hyperparameters**

Preset: Medium Gaussian SVM  
 Kernel function: Gaussian  
 Kernel scale: 2.2  
 Box constraint: Automatic  
 Epsilon: Auto  
 Standardize data: Yes

► Feature Selection: 5/5 individual features selected  
 ► PCA: Disabled  
 ► Optimizer: Not applicable

**TABLA 24 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 113 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## CONO B: ENTRENAMIENTO DEL DÍA 2 AL 9 Y TEST DEL 10 AL 16

Sort by Model Number ▾

Model 2.16 Ensemble RMSE (Test): 0.011942  
Last change: Boosted Trees 5/5 features

Model 2.17 Ensemble RMSE (Test): 0.012072  
Last change: Bagged Trees 5/5 features

Model 2.18 Gaussian Process Regression RMSE (Test): 0.013903  
Last change: Squared Exponential GPR 5/5 features

Model 2.19 Gaussian Process Regression RMSE (Test): 0.014518  
Last change: Matern 5/2 GPR 5/5 features

Model 2.20 Gaussian Process Regression RMSE (Test): 0.013114  
Last change: Exponential GPR 5/5 features

Model 2.21 Gaussian Process Regression RMSE (Test): 0.011621  
Last change: Rational Quadratic GPR 5/5 features

Model 2.22 Neural Network RMSE (Test): 2.5108e+09  
Last change: Narrow Neural Network 5/5 features

Model 2.23 Neural Network RMSE (Test): 5.5691e+08  
Last change: Medium Neural Network 5/5 features

Model 2.24 Neural Network RMSE (Test): 7.5546e+08  
Last change: Wide Neural Network 5/5 features

Model 2.25 Neural Network RMSE (Test): 1.0597e+09  
Last change: Bilayered Neural Network 5/5 features

Model 2.26 Neural Network RMSE (Test): 2.9995e+08  
Last change: Trilayered Neural Network 5/5 features

**Model 2.21: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.0093050
R-Squared (Validation)	0.60
MSE (Validation)	8.6584e-05
MAE (Validation)	0.0063866
MAPE (Validation)	234.6%
Prediction speed	~6300 obs/sec
Training time	527.34 sec
Model size (Compact)	~267 kB

**Test Results**

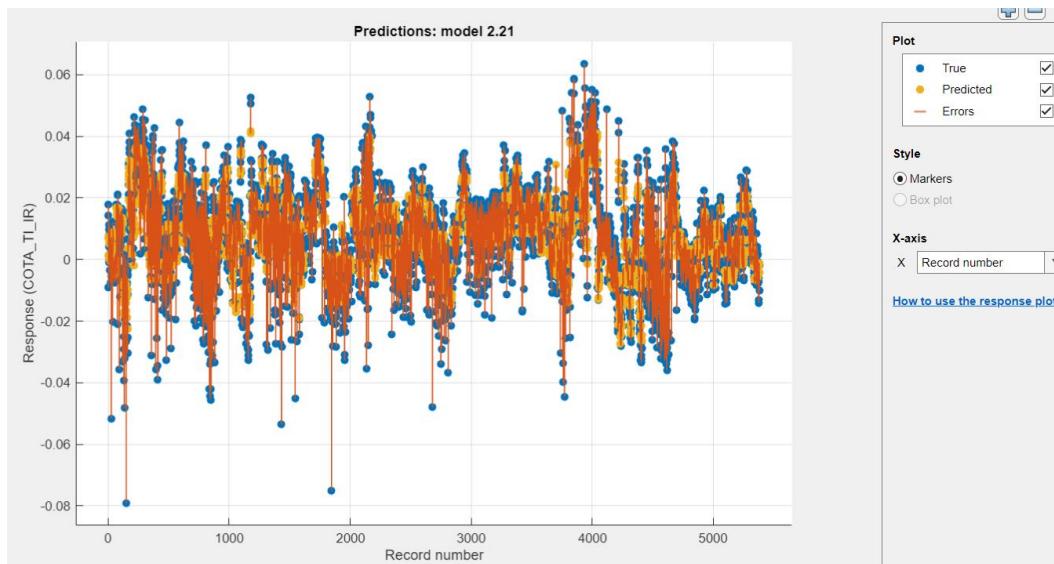
RMSE (Test)	0.011621
R-Squared (Test)	0.30
MSE (Test)	0.00013504
MAE (Test)	0.0091529
MAPE (Test)	510.8%

**Model Hyperparameters**

Preset: Rational Quadratic GPR  
Basis function: Constant  
Kernel function: Rational Quadratic  
Use isotropic kernel: Yes  
Kernel scale: Automatic  
Signal standard deviation: Automatic  
Sigma: Automatic  
Standardize data: Yes  
Optimize numeric parameters: Yes

► Feature Selection: 5/5 individual features selected  
► PCA: Disabled  
► Optimizer: Not applicable

**TABLA 25 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 114 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## CONO A: ENTRENAMIENTO DEL DÍA 10 AL 16 Y TEST DEL 19 AL 24

Last change: Medium Gaussian SVM	5/5 features	▲
2.13 SVM	RMSE (Test): 0.013556	
Last change: Coarse Gaussian SVM	5/5 features	
2.14 Efficient Linear	RMSE (Test): 0.058747	
Last change: Efficient Linear Least Squares	5/5 features	
2.15 Efficient Linear	RMSE (Test): 0.072512	
Last change: Efficient Linear SVM	5/5 features	
2.16 Ensemble	RMSE (Test): 0.015196	
Last change: Boosted Trees	5/5 features	
2.17 Ensemble	RMSE (Test): 0.014835	
Last change: Bagged Trees	5/5 features	
2.18 Gaussian Process Regression	RMSE (Test): 0.013431	
Last change: Squared Exponential GPR	5/5 features	
2.19 Gaussian Process Regression	RMSE (Test): 0.013460	
Last change: Matern 5/2 GPR	5/5 features	
2.20 Gaussian Process Regression	RMSE (Test): 0.013849	
Last change: Exponential GPR	5/5 features	
2.21 Gaussian Process Regression	RMSE (Test): 0.013648	
Last change: Rational Quadratic GPR	5/5 features	
2.22 Neural Network	RMSE (Test): 0.16533	
Last change: Narrow Neural Network	5/5 features	
2.23 Neural Network	RMSE (Test): 0.76567	
Last change: Medium Neural Network	5/5 features	
2.24 Neural Network	RMSE (Test): 0.072168	
Last change: Wide Neural Network	5/5 features	

**Model 2.19: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.0057934
R-Squared (Validation)	0.81
MSE (Validation)	3.3564e-05
MAE (Validation)	0.0041856
MAPE (Validation)	2339.1%
Prediction speed	~11000 obs/sec
Training time	166.31 sec
Model size (Compact)	~165 kB

**Test Results**

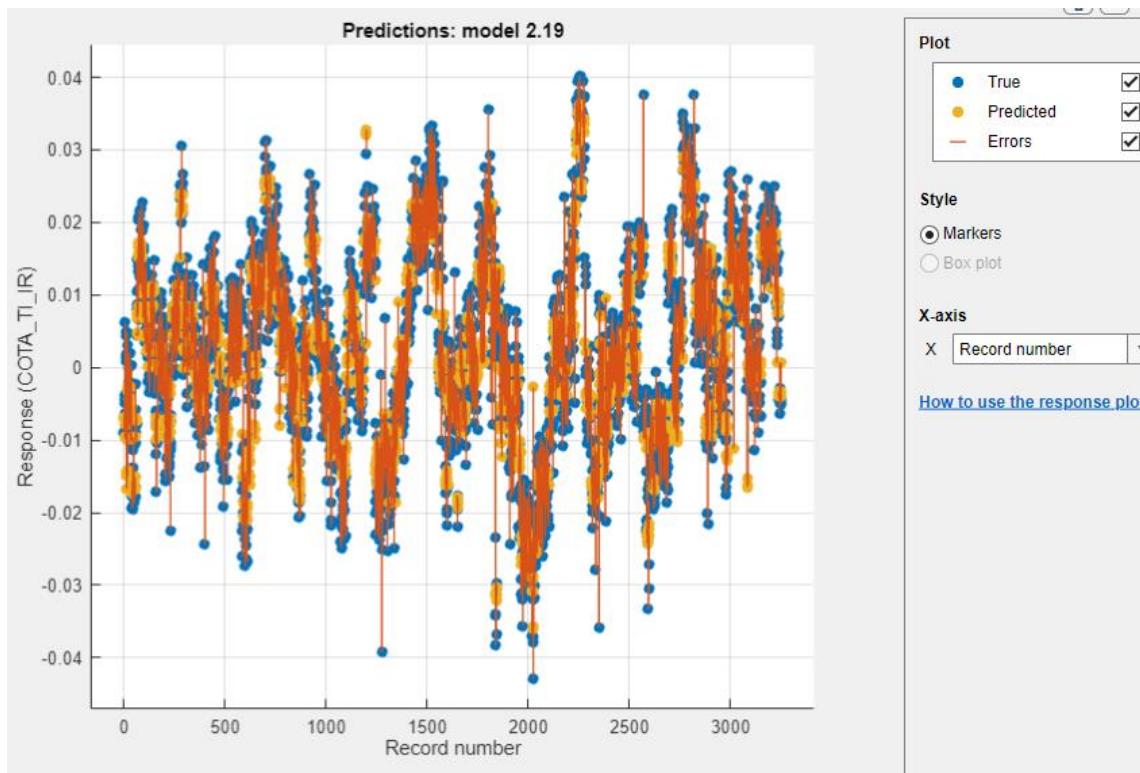
RMSE (Test)	0.013460
R-Squared (Test)	-0.02
MSE (Test)	0.00018118
MAE (Test)	0.010040
MAPE (Test)	140.9%

▼ **Model Hyperparameters**

Preset: Matern 5/2 GPR  
 Basis function: Constant  
 Kernel function: Matern 5/2  
 Use isotropic kernel: Yes  
 Kernel scale: Automatic  
 Signal standard deviation: Automatic  
 Sigma: Automatic  
 Standardize data: Yes  
 Optimize numeric parameters: Yes

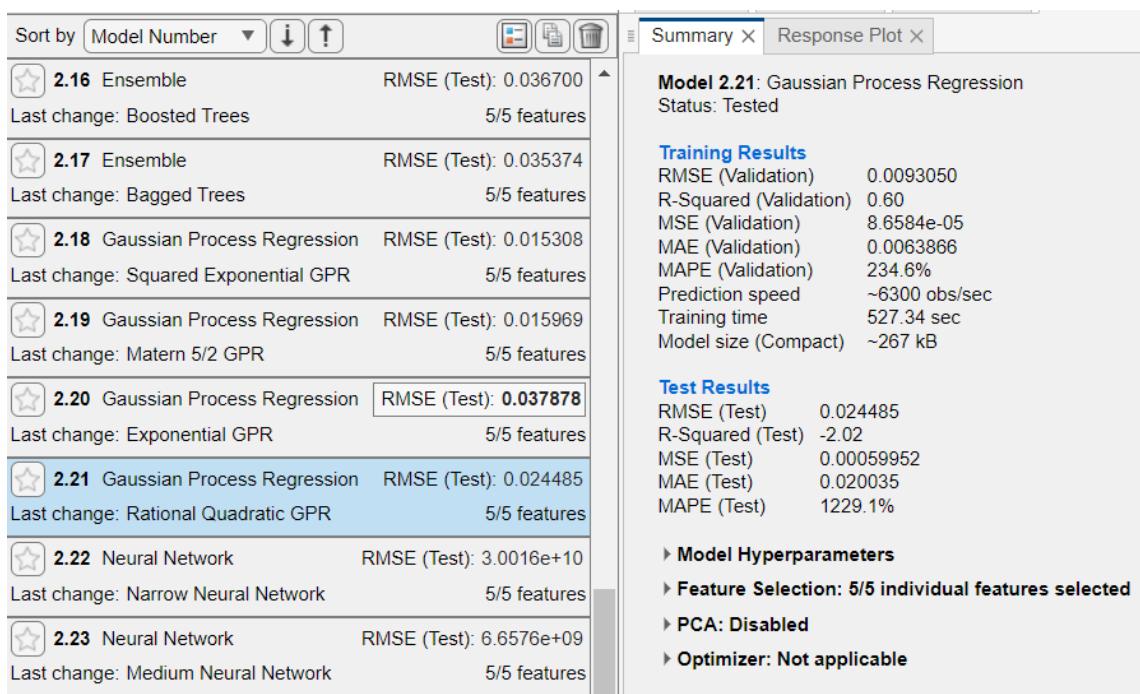
► Feature Selection: 5/5 individual features selected  
 ► PCA: Disabled  
 ► Optimizer: Not applicable

**TABLA 26 MODELOS DE ENTRENAMIENTO DE LOS CONOS**

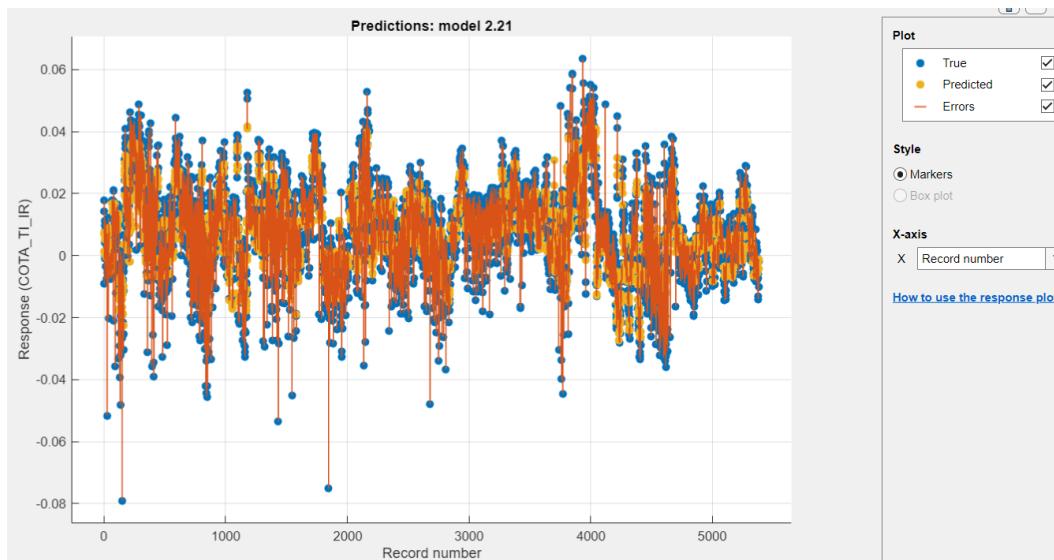


**ILUSTRACIÓN 115 GRÁFICA COMPARATIVA DE LAS PREDICIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

### CONO B: ENTRENAMIENTO DEL DÍA 2 AL 9 Y TEST DEL 19 AL 24

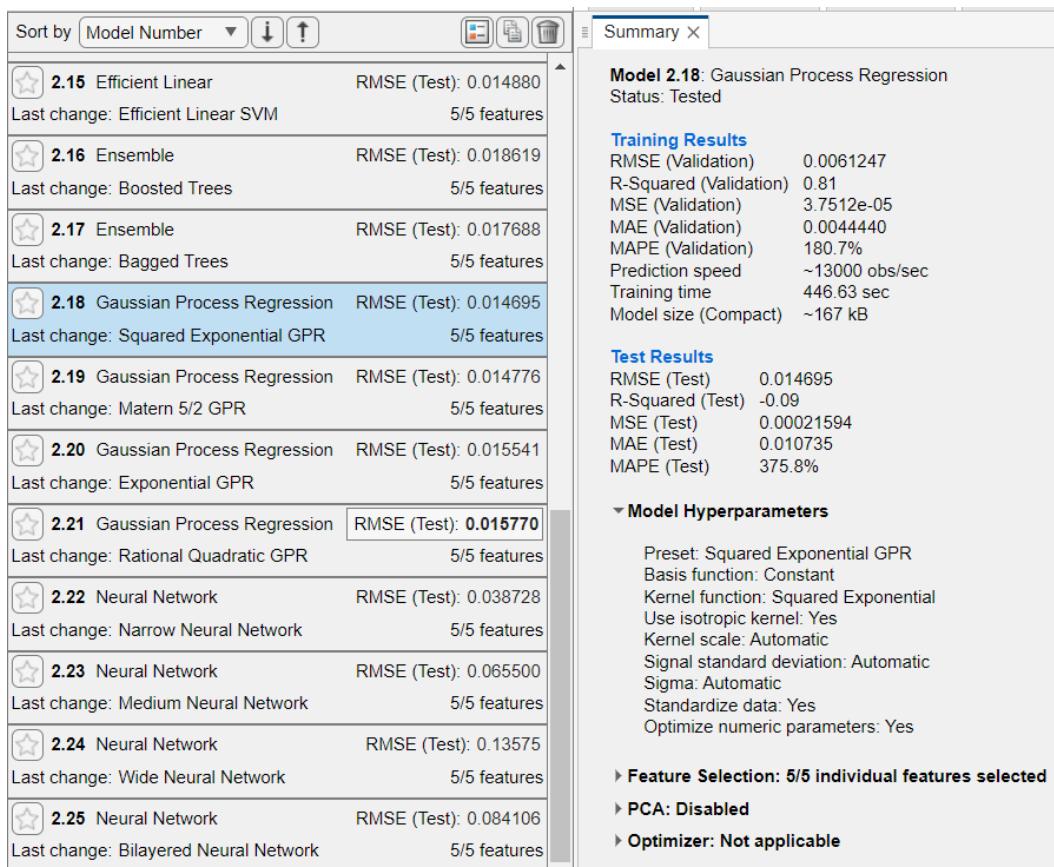


**TABLA 27 MODELOS DE ENTRENAMIENTO DE LOS CONOS**

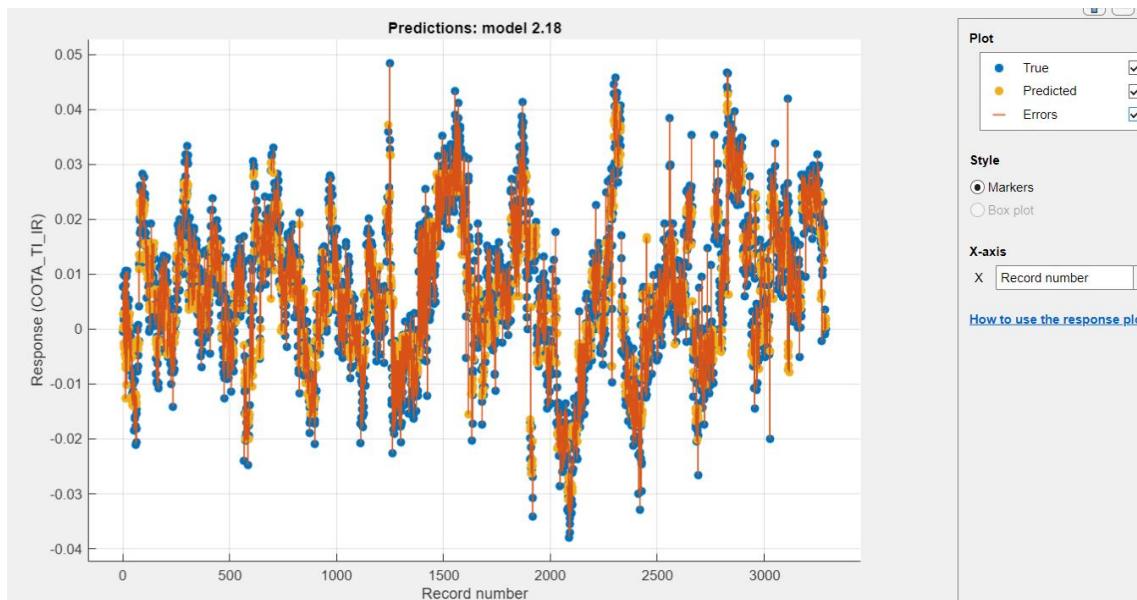


**ILUSTRACIÓN 116 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

### CONO B: ENTRENAMIENTO DEL DÍA 10 AL 16 Y TEST DEL 19 AL 24



**TABLA 28 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 117 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## ENTRENAMIENTO Y TEST POR DÍAS

### ENTRENAMIENTO CONO A DÍA 3 Y TEST CONO B DÍA 4

Last change: Medium Gaussian SVM		5/5 features
<span style="color: #808000;">★</span>	2.13 SVM	RMSE (Test): 0.0098771
Last change: Coarse Gaussian SVM		5/5 features
<span style="color: #808000;">★</span>	2.14 Efficient Linear	RMSE (Test): 0.010369
Last change: Efficient Linear Least Squares		5/5 features
<span style="color: #808000;">★</span>	2.15 Efficient Linear	RMSE (Test): 0.014102
Last change: Efficient Linear SVM		5/5 features
<span style="color: #808000;">★</span>	2.16 Ensemble	RMSE (Test): 0.010906
Last change: Boosted Trees		5/5 features
<span style="color: #808000;">★</span>	2.17 Ensemble	RMSE (Test): 0.011185
Last change: Bagged Trees		5/5 features
<span style="color: #808000;">★</span>	2.18 Gaussian Process Regression	RMSE (Test): 0.010947
Last change: Squared Exponential GPR		5/5 features
<span style="color: #808000;">★</span>	2.19 Gaussian Process Regression	RMSE (Test): 0.010675
Last change: Matern 5/2 GPR		5/5 features
<span style="color: #808000;">★</span>	2.20 Gaussian Process Regression	RMSE (Test): 0.010389
Last change: Exponential GPR		5/5 features
<span style="color: #808000;">★</span>	2.21 Gaussian Process Regression	RMSE (Test): 0.010689
Last change: Rational Quadratic GPR		5/5 features
<span style="color: #808000;">★</span>	2.22 Neural Network	RMSE (Test): 1.3462e+12
Last change: Narrow Neural Network		5/5 features
<span style="color: #808000;">★</span>	2.23 Neural Network	RMSE (Test): 2.2643e+11
Last change: Medium Neural Network		5/5 features

**Model 2.20: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.012042
R-Squared (Validation)	0.50
MSE (Validation)	0.00014501
MAE (Validation)	0.0079068
MAPE (Validation)	147.4%
Prediction speed	~18000 obs/sec
Training time	29.816 sec
Model size (Compact)	~66 kB

**Test Results**

RMSE (Test)	0.010389
R-Squared (Test)	0.47
MSE (Test)	0.00010793
MAE (Test)	0.0072454
MAPE (Test)	576.2%

**Model Hyperparameters**

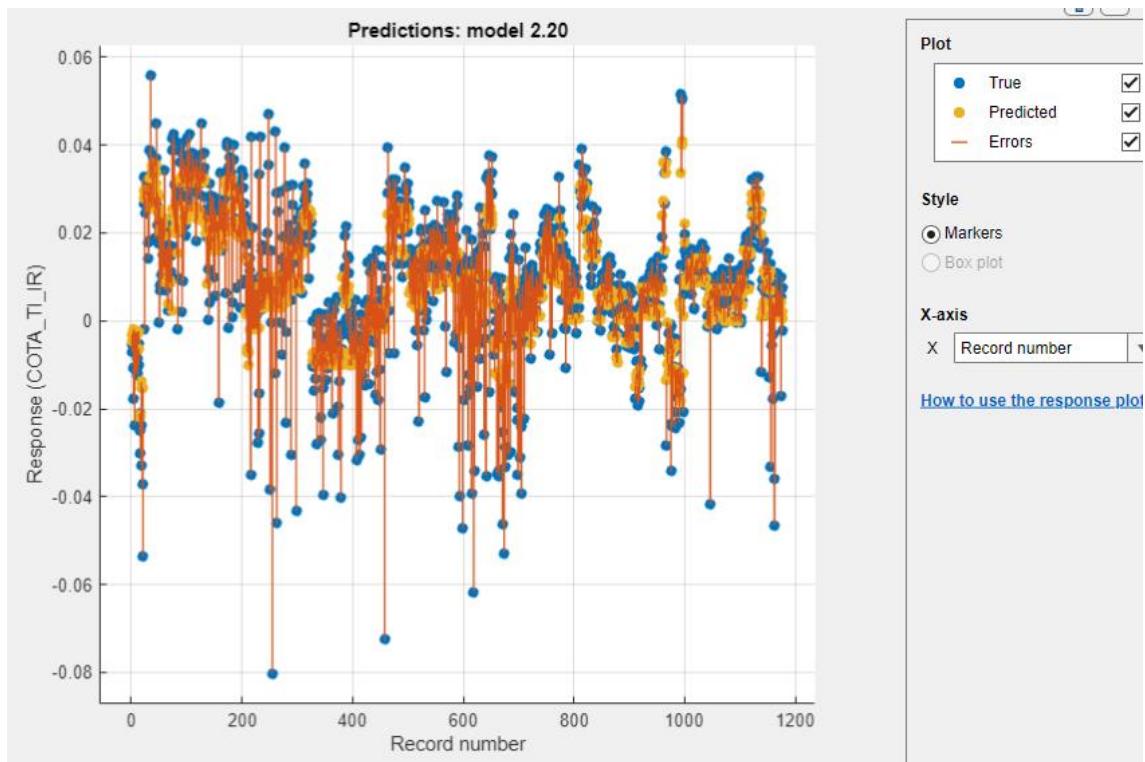
- Preset: Exponential GPR
- Basis function: Constant
- Kernel function: Exponential
- Use isotropic kernel: Yes
- Kernel scale: Automatic
- Signal standard deviation: Automatic
- Sigma: Automatic
- Standardize data: Yes
- Optimize numeric parameters: Yes

► Feature Selection: 5/5 individual features selected

► PCA: Disabled

► Optimizer: Not applicable

**TABLA 29 MODELOS DE ENTRENAMIENTO DE LOS CONOS**

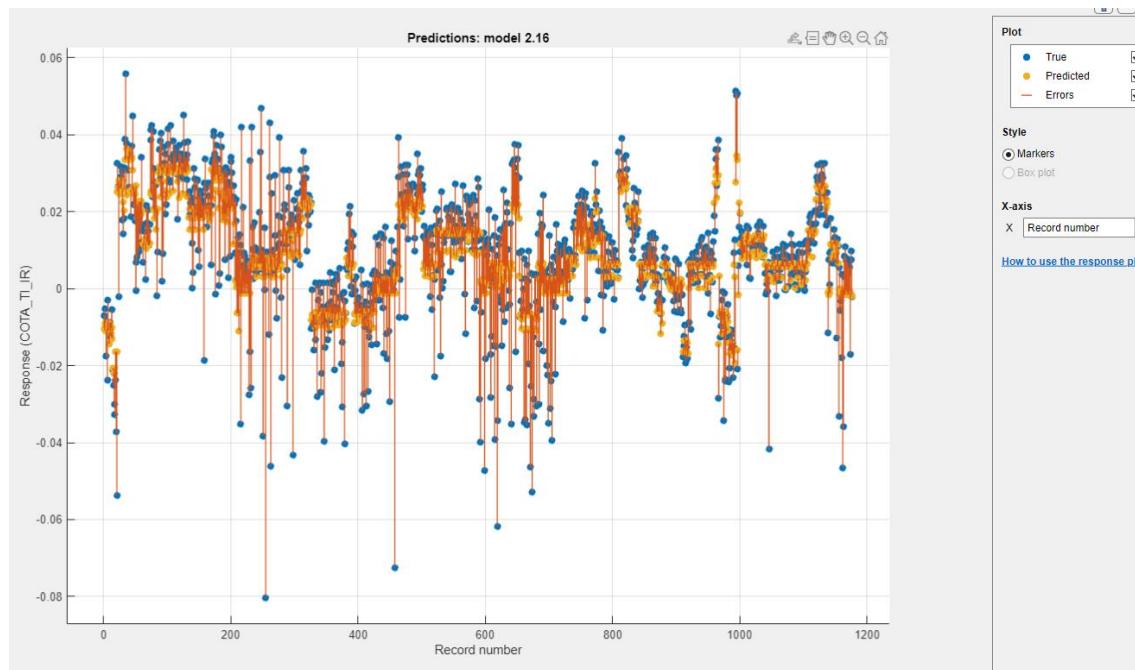


**ILUSTRACIÓN 118 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## ENTRENAMIENTO CONO A DÍA 3 Y TEST CONO B DÍA 11

Last change: Medium Gaussian SVM	5/5 features	Model 2.16: Ensemble
2.13 SVM	RMSE (Test): 0.015188	Status: Tested
Last change: Coarse Gaussian SVM	5/5 features	
2.14 Efficient Linear	RMSE (Test): 0.018763	<b>Training Results</b>
Last change: Efficient Linear Least Squares	5/5 features	RMSE (Validation): 0.011907 R-Squared (Validation): 0.51 MSE (Validation): 0.00014178 MAE (Validation): 0.0078937 MAPE (Validation): 144.5% Prediction speed: ~11000 obs/sec Training time: 7.2021 sec Model size (Compact): ~156 kB
2.15 Efficient Linear	RMSE (Test): 0.013803	
Last change: Efficient Linear SVM	5/5 features	
2.16 Ensemble	RMSE (Test): 0.0078289	<b>Test Results</b>
Last change: Boosted Trees	5/5 features	RMSE (Test): 0.0078289 R-Squared (Test): 0.68 MSE (Test): 6.1292e-05 MAE (Test): 0.0064576 MAPE (Test): 225.0%
2.17 Ensemble	RMSE (Test): 0.0083636	
Last change: Bagged Trees	5/5 features	<b>Model Hyperparameters</b>
2.18 Gaussian Process Regression	RMSE (Test): 0.014192	▶ Feature Selection: 5/5 individual features selected
Last change: Squared Exponential GPR	5/5 features	▶ PCA: Disabled
2.19 Gaussian Process Regression	RMSE (Test): 0.013606	▶ Optimizer: Not applicable
Last change: Matern 5/2 GPR	5/5 features	
2.20 Gaussian Process Regression	RMSE (Test): 0.012392	
Last change: Exponential GPR	5/5 features	

**TABLA 30 MODELOS DE ENTRENAMIENTO DE LOS CONOS**

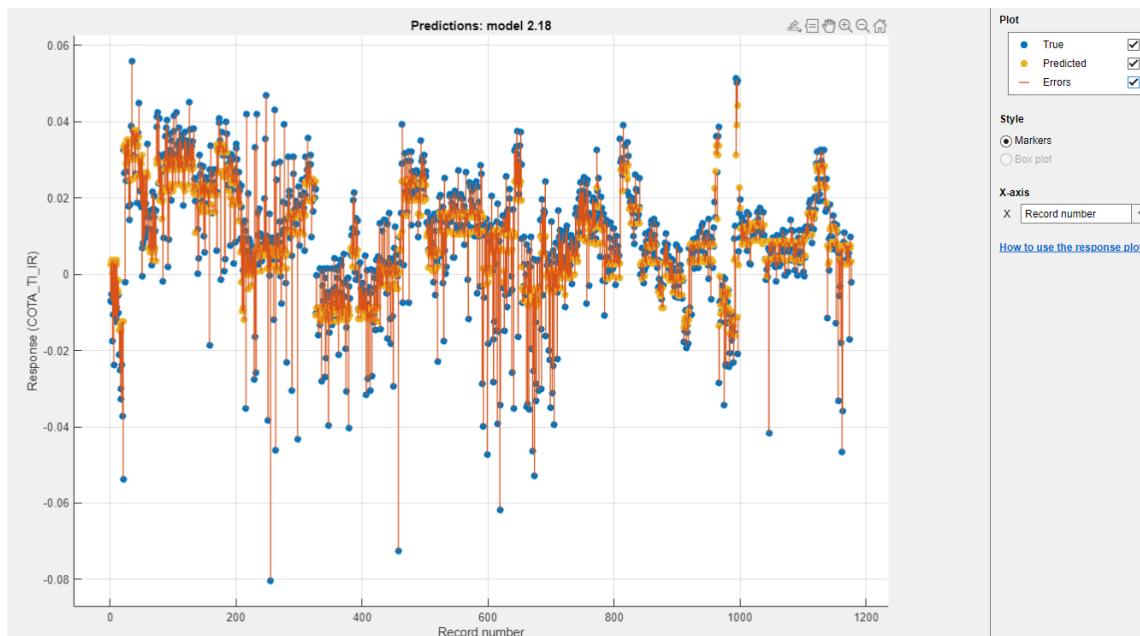


**ILUSTRACIÓN 119 GRÁFICA COMPARATIVA DE LAS PREDICCIÓNES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## ENTRENAMIENTO CONO A DÍA 3 Y TEST CONO B DÍA 20

Last change: Medium Gaussian SVM	5/5 features	Model 2.18: Gaussian Process Regression
2.13 SVM	RMSE (Test): 0.014300	Status: Tested
Last change: Coarse Gaussian SVM	5/5 features	
2.14 Efficient Linear	RMSE (Test): 0.089411	<b>Training Results</b>
Last change: Efficient Linear Least Squares	5/5 features	RMSE (Validation): 0.012204 R-Squared (Validation): 0.48 MSE (Validation): 0.00014893 MAE (Validation): 0.0081262 MAPE (Validation): 147.4% Prediction speed: ~21000 obs/sec Training time: 25.215 sec Model size (Compact): ~66 kB
2.15 Efficient Linear	RMSE (Test): 0.011896	
Last change: Efficient Linear SVM	5/5 features	
2.16 Ensemble	RMSE (Test): 0.027004	<b>Test Results</b>
Last change: Boosted Trees	5/5 features	RMSE (Test): 0.013569 R-Squared (Test): -0.34 MSE (Test): 0.00018413 MAE (Test): 0.010170 MAPE (Test): 730.4%
2.17 Ensemble	RMSE (Test): 0.029701	
Last change: Bagged Trees	5/5 features	<b>Model Hyperparameters</b>
2.18 Gaussian Process Regression	RMSE (Test): 0.013569	Preset: Squared Exponential GPR Basis function: Constant Kernel function: Squared Exponential Use isotropic kernel: Yes Kernel scale: Automatic Signal standard deviation: Automatic Sigma: Automatic Standardize data: Yes Optimize numeric parameters: Yes
Last change: Squared Exponential GPR	5/5 features	
2.19 Gaussian Process Regression	RMSE (Test): 0.017899	<b>Feature Selection:</b> 5/5 individual features selected
Last change: Matern 5/2 GPR	5/5 features	
2.20 Gaussian Process Regression	RMSE (Test): 0.028626	<b>PCA:</b> Disabled
Last change: Exponential GPR	5/5 features	
2.21 Gaussian Process Regression	RMSE (Test): 0.019559	<b>Optimizer:</b> Not applicable
Last change: Rational Quadratic GPR	5/5 features	
2.22 Neural Network	RMSE (Test): 6.6964e+11	
Last change: Narrow Neural Network	5/5 features	
2.23 Neural Network	RMSE (Test): 3.2374e+09	
Last change: Medium Neural Network	5/5 features	

**TABLA 31 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 120 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

### ENTRENAMIENTO CONO A DÍA 23 Y TEST CONO B DÍA 23

Last change: Efficient Linear Least Squares	5/5 features
2.15 Efficient Linear	RMSE (Test): 0.0077956
Last change: Efficient Linear SVM	5/5 features
2.16 Ensemble	RMSE (Test): 0.0060583
Last change: Boosted Trees	5/5 features
2.17 Ensemble	RMSE (Test): 0.0059787
Last change: Bagged Trees	5/5 features
2.18 Gaussian Process Regression	RMSE (Test): 0.0064448
Last change: Squared Exponential GPR	5/5 features
2.19 Gaussian Process Regression	RMSE (Test): 0.0063125
Last change: Matern 5/2 GPR	5/5 features
2.20 Gaussian Process Regression	RMSE (Test): 0.0057379
Last change: Exponential GPR	5/5 features
2.21 Gaussian Process Regression	RMSE (Test): 0.0057524
Last change: Rational Quadratic GPR	5/5 features
2.22 Neural Network	RMSE (Test): 2.1445e+12
Last change: Narrow Neural Network	5/5 features
2.23 Neural Network	RMSE (Test): 1.0050e+12
Last change: Medium Neural Network	5/5 features
2.24 Neural Network	RMSE (Test): 1.1431e+12
Last change: Wide Neural Network	5/5 features
2.25 Neural Network	RMSE (Test): 8.1516e+10
Last change: Bilayered Neural Network	5/5 features

**Model 2.20: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.0047832
R-Squared (Validation)	0.83
MSE (Validation)	2.2879e-05
MAE (Validation)	0.0033584
MAPE (Validation)	181.8%
Prediction speed	~15000 obs/sec
Training time	44.072 sec
Model size (Compact)	~76 kB

**Test Results**

RMSE (Test)	0.0057379
R-Squared (Test)	0.77
MSE (Test)	3.2923e-05
MAE (Test)	0.0040260
MAPE (Test)	178.0%

**Model Hyperparameters**

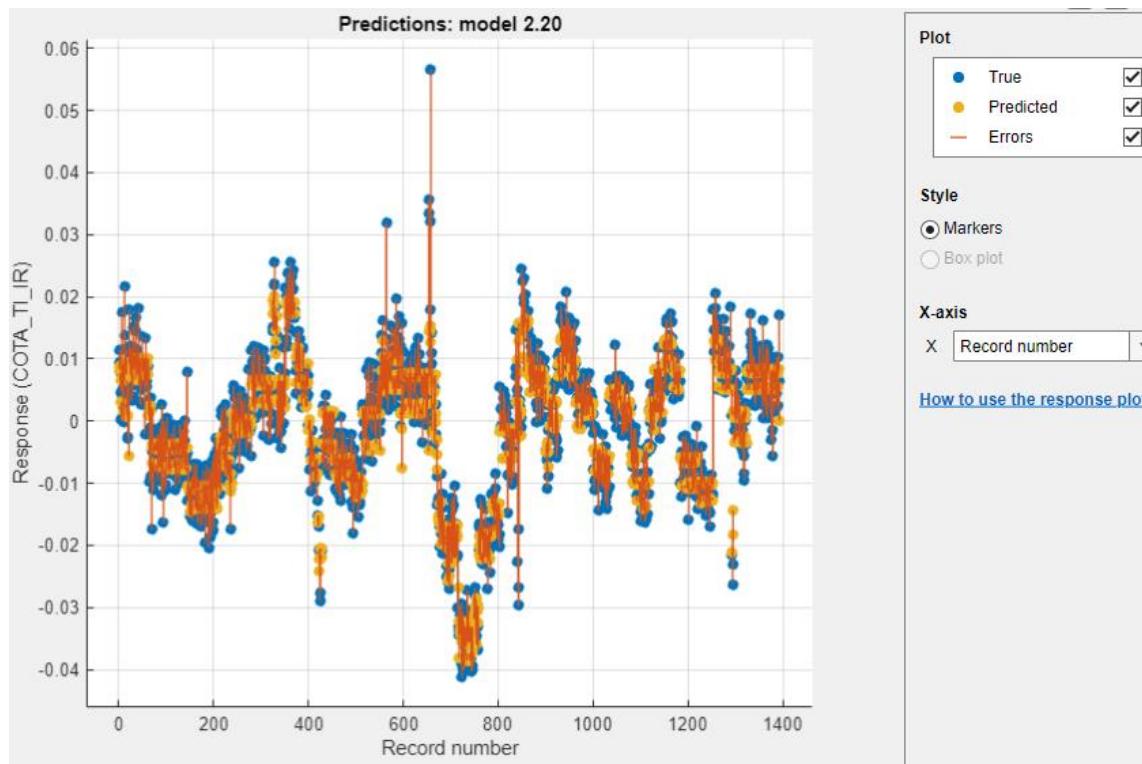
- Preset: Exponential GPR
- Basis function: Constant
- Kernel function: Exponential
- Use isotropic kernel: Yes
- Kernel scale: Automatic
- Signal standard deviation: Automatic
- Sigma: Automatic
- Standardize data: Yes
- Optimize numeric parameters: Yes

Feature Selection: 5/5 individual features selected

PCA: Disabled

Optimizer: Not applicable

**TABLA 32 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 121 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS CONOS**

## ANEXO 4 AROS

### ENTRENAMIENTO Y TEST POR MUELAS

#### ENTRENAMIENTO MUELA 7 Y TEST MUELA 36

 <b>2.17</b> Ensemble	RMSE (Test): 0.022916
Last change: Bagged Trees	5/5 features
 <b>2.18</b> Gaussian Process Regression	RMSE (Test): 0.022409
Last change: Squared Exponential GPR	5/5 features
 <b>2.19</b> Gaussian Process Regression	RMSE (Test): 0.022429
Last change: Matern 5/2 GPR	5/5 features
 <b>2.20</b> Gaussian Process Regression	RMSE (Test): <b>0.021730</b>
Last change: Exponential GPR	5/5 features
 <b>2.21</b> Gaussian Process Regression	RMSE (Test): 0.020632
Last change: Rational Quadratic GPR	5/5 features
 <b>2.22</b> Neural Network	RMSE (Test): 0.16255
Last change: Narrow Neural Network	5/5 features
 <b>2.23</b> Neural Network	RMSE (Test): 2.5549
Last change: Medium Neural Network	5/5 features
 <b>2.24</b> Neural Network	RMSE (Test): 0.75006
Last change: Wide Neural Network	5/5 features
 <b>2.25</b> Neural Network	RMSE (Test): 0.31290
Last change: Bilayered Neural Network	5/5 features
 <b>2.26</b> Neural Network	RMSE (Test): 0.84985
Last change: Trilayered Neural Network	5/5 features
 <b>2.27</b> Kernel	RMSE (Test): 0.031387
Last change: SVM Kernel	5/5 features

**Model 2.21: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.017572
R-Squared (Validation)	0.56
MSE (Validation)	0.00030877
MAE (Validation)	0.011477
MAPE (Validation)	376.0%
Prediction speed	~6400 obs/sec
Training time	10.021 sec
Model size (Compact)	~28 kB

**Test Results**

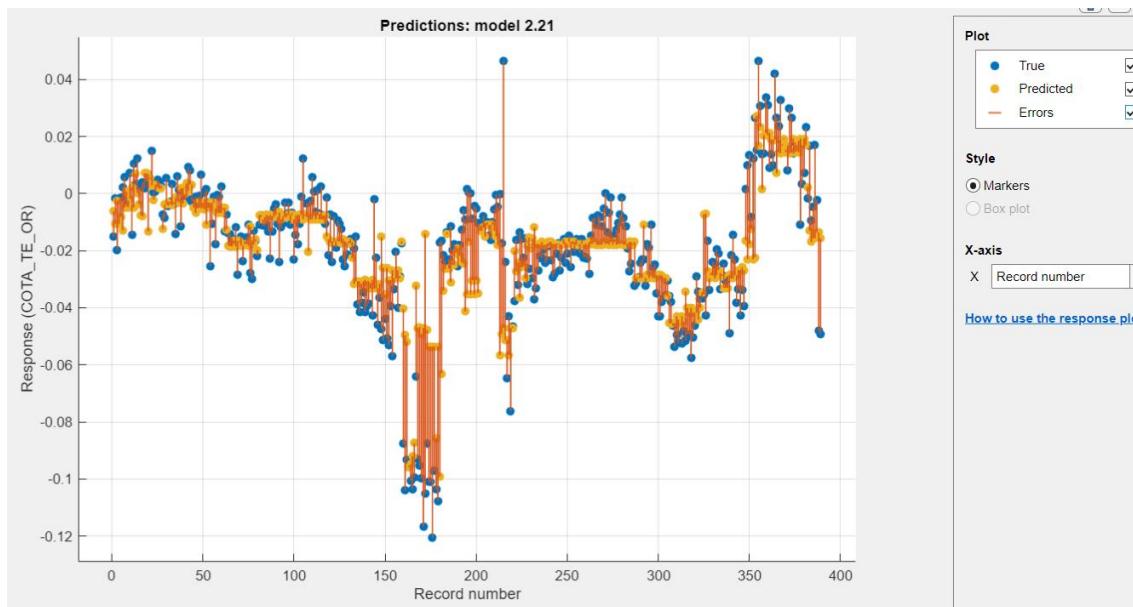
RMSE (Test)	0.020632
R-Squared (Test)	-0.03
MSE (Test)	0.00042568
MAE (Test)	0.016468
MAPE (Test)	340.2%

▼ **Model Hyperparameters**

Preset: Rational Quadratic GPR  
 Basis function: Constant  
 Kernel function: Rational Quadratic  
 Use isotropic kernel: Yes  
 Kernel scale: Automatic  
 Signal standard deviation: Automatic  
 Sigma: Automatic  
 Standardize data: Yes  
 Optimize numeric parameters: Yes

► **Feature Selection: 5/5 individual features selected**  
 ► **PCA: Disabled**  
 ► **Optimizer: Not applicable**

**TABLA 33 MODELOS DE ENTRENAMIENTO DE LOS AROS**

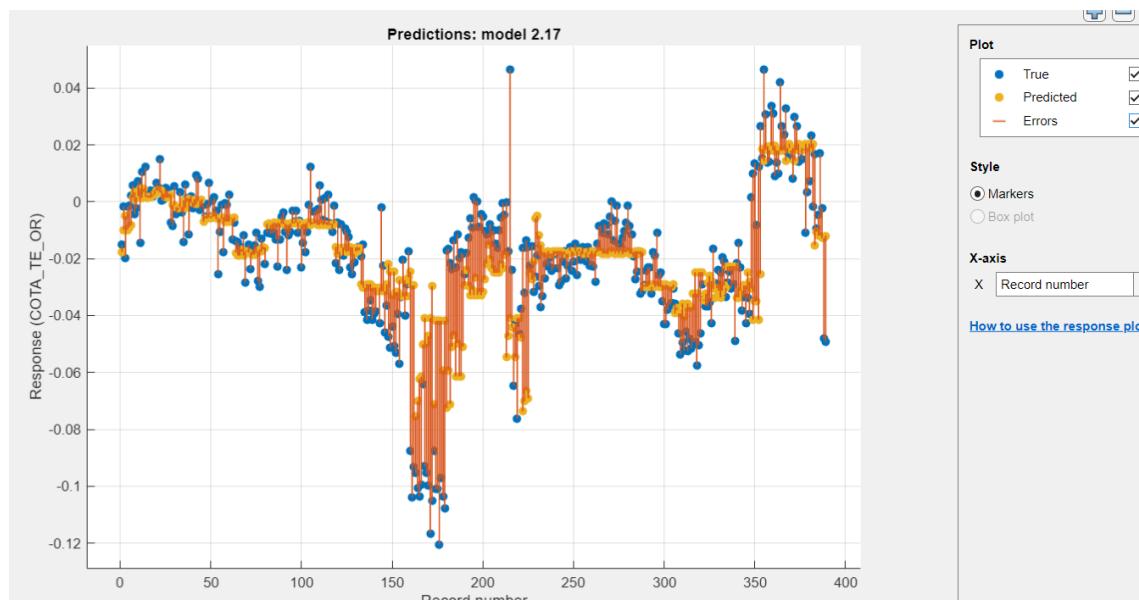


**ILUSTRACIÓN 122 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

## ENTRENAMIENTO MUELA 7 Y TEST MUELA 38

<b>2.16</b> Ensemble	RMSE (Test): 0.024451	<b>Model 2.17: Ensemble</b> Status: Tested  <b>Training Results</b> RMSE (Validation) 0.020206 R-Squared (Validation) 0.42 MSE (Validation) 0.00040827 MAE (Validation) 0.013287 MAPE (Validation) 385.1% Prediction speed ~2700 obs/sec Training time 3.932 sec Model size (Compact) ~233 kB  <b>Test Results</b> RMSE (Test) 0.024411 R-Squared (Test) -0.00 MSE (Test) 0.00059592 MAE (Test) 0.020490 MAPE (Test) 166.0%  <b>Model Hyperparameters</b> Preset: Bagged Trees Minimum leaf size: 8 Number of learners: 30 Number of predictors to sample: Select All  <b>Feature Selection: 5/5 individual features selected</b> <b>PCA: Disabled</b> <b>Optimizer: Not applicable</b>
Last change: Boosted Trees	5/5 features	
<b>2.17</b> Ensemble	RMSE (Test): 0.024411	
Last change: Bagged Trees	5/5 features	
<b>2.18</b> Gaussian Process Regression	RMSE (Test): 0.030549	
Last change: Squared Exponential GPR	5/5 features	
<b>2.19</b> Gaussian Process Regression	RMSE (Test): 0.030577	
Last change: Matern 5/2 GPR	5/5 features	
<b>2.20</b> Gaussian Process Regression	RMSE (Test): <b>0.029519</b>	
Last change: Exponential GPR	5/5 features	
<b>2.21</b> Gaussian Process Regression	RMSE (Test): 0.027389	
Last change: Rational Quadratic GPR	5/5 features	
<b>2.22</b> Neural Network	RMSE (Test): 0.60491	
Last change: Narrow Neural Network	5/5 features	
<b>2.23</b> Neural Network	RMSE (Test): 0.90499	
Last change: Medium Neural Network	5/5 features	
<b>2.24</b> Neural Network	RMSE (Test): 1.7767	
Last change: Wide Neural Network	5/5 features	
<b>2.25</b> Neural Network	RMSE (Test): 0.27360	
Last change: Bilayered Neural Network	5/5 features	

**TABLA 34 MODELOS DE ENTRENAMIENTO DE LOS CONOS**



**ILUSTRACIÓN 123 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

## ENTRENO Y TESTEO POR SEMANA Y POR DÍAS

### ENTRENAMIENTO DEL 3 AL 9 Y TEST DEL 10 AL 16 (1 SEMANA)

Last change: Medium Gaussian SVM		5/5 features
 2.13 SVM		RMSE (Test): 0.027842
Last change: Coarse Gaussian SVM		5/5 features
 2.14 Efficient Linear		RMSE (Test): 0.027464
Last change: Efficient Linear Least Squares		5/5 features
 2.15 Efficient Linear		RMSE (Test): 0.027289
Last change: Efficient Linear SVM		5/5 features
 2.16 Ensemble		RMSE (Test): 0.041738
Last change: Boosted Trees		5/5 features
 2.17 Ensemble		RMSE (Test): 0.043278
Last change: Bagged Trees		5/5 features
 2.18 Gaussian Process Regression		RMSE (Test): 0.027096
Last change: Squared Exponential GPR		5/5 features
 2.19 Gaussian Process Regression		RMSE (Test): 0.027182
Last change: Matern 5/2 GPR		5/5 features
 2.20 Gaussian Process Regression		RMSE (Test): 0.027255
Last change: Exponential GPR		5/5 features
 2.21 Gaussian Process Regression		RMSE (Test): 0.026022
Last change: Rational Quadratic GPR		5/5 features

#### Model 2.21: Gaussian Process Regression

Status: Tested

##### Training Results

RMSE (Validation) 0.016572  
 R-Squared (Validation) 0.62  
 MSE (Validation) 0.00027462  
 MAE (Validation) 0.011481  
 MAPE (Validation) 197.6%  
 Prediction speed ~5600 obs/sec  
 Training time 1022.3 sec  
 Model size (Compact) ~235 kB

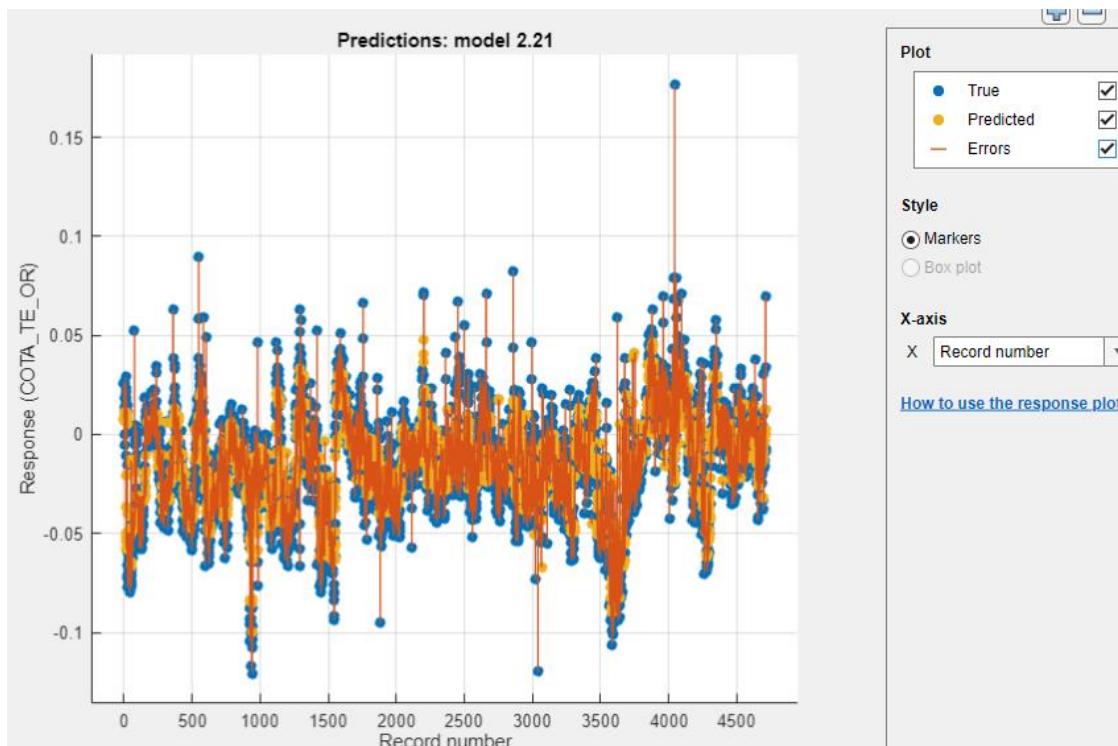
##### Test Results

RMSE (Test) 0.026022  
 R-Squared (Test) 0.04  
 MSE (Test) 0.00067713  
 MAE (Test) 0.019647  
 MAPE (Test) 298.3%

##### Model Hyperparameters

- ▶ Feature Selection: 5/5 individual features selected
- ▶ PCA: Disabled
- ▶ Optimizer: Not applicable

**TABLA 35 MODELOS DE ENTRENAMIENTO DE LOS AROS**



**ILUSTRACIÓN 124 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

## ENTRENAMIENTO DEL 3 AL 16 Y TEST DEL 16 AL 30 (2 SEMANAS)

Last change: Medium Gaussian SVM	5/5 features
2.13 SVM	RMSE (Test): 0.031767
Last change: Coarse Gaussian SVM	5/5 features
2.14 Efficient Linear	RMSE (Test): 0.027360
Last change: Efficient Linear Least Squares	5/5 features
2.15 Efficient Linear	RMSE (Test): 0.027379
Last change: Efficient Linear SVM	5/5 features
2.16 Ensemble	RMSE (Test): 0.026669
Last change: Boosted Trees	5/5 features
2.17 Ensemble	RMSE (Test): 0.025930
Last change: Bagged Trees	5/5 features
2.18 Gaussian Process Regression	RMSE (Test): 0.027287
Last change: Squared Exponential GPR	5/5 features
2.19 Gaussian Process Regression	RMSE (Test): 0.026270
Last change: Matern 5/2 GPR	5/5 features
2.20 Gaussian Process Regression	RMSE (Test): 0.026317
Last change: Exponential GPR	5/5 features
2.21 Gaussian Process Regression	RMSE (Test): 0.025766
Last change: Rational Quadratic GPR	5/5 features
2.22 Neural Network	RMSE (Test): 0.11181
Last change: Narrow Neural Network	5/5 features
2.23 Neural Network	RMSE (Test): 0.065411
Last change: Medium Neural Network	5/5 features

**Model 2.21: Gaussian Process Regression**  
 Status: Tested

**Training Results**

RMSE (Validation)	0.017236
R-Squared (Validation)	0.59
MSE (Validation)	0.00029708
MAE (Validation)	0.011787
MAPE (Validation)	229.8%
Prediction speed	~2700 obs/sec
Training time	1140.3 sec
Model size (Compact)	~381 KB

**Test Results**

RMSE (Test)	0.025766
R-Squared (Test)	-0.01
MSE (Test)	0.00066390
MAE (Test)	0.019929
MAPE (Test)	243.7%

**Model Hyperparameters**

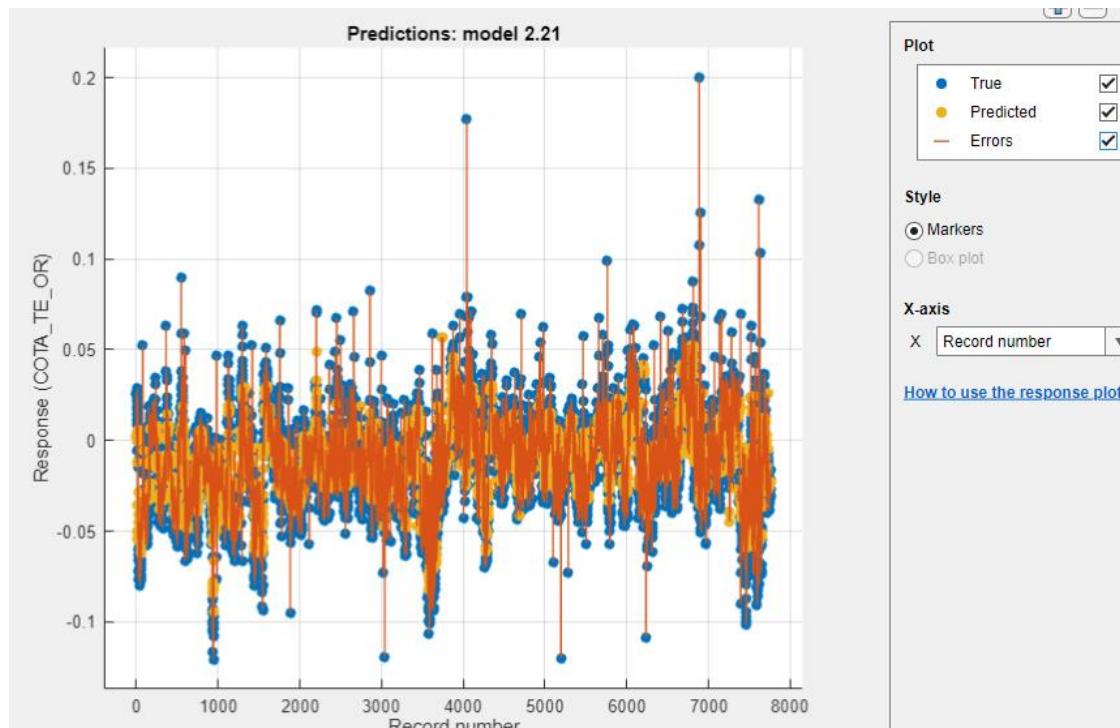
- Preset: Rational Quadratic GPR
- Basis function: Constant
- Kernel function: Rational Quadratic
- Use isotropic kernel: Yes
- Kernel scale: Automatic
- Signal standard deviation: Automatic
- Sigma: Automatic
- Standardize data: Yes
- Optimize numeric parameters: Yes

Feature Selection: 5/5 individual features selected

PCA: Disabled

Optimizer: Not applicable

**TABLA 36 MODELOS DE ENTRENAMIENTO DE LOS AROS**



**ILUSTRACIÓN 125 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

Sort by Model Number ▾

Last change: Medium Gaussian SVM 5/5 features

2.13 SVM RMSE (Test): 0.049048

Last change: Coarse Gaussian SVM 5/5 features

2.14 Efficient Linear RMSE (Test): 0.026767

Last change: Efficient Linear Least Squares 5/5 fea

2.15 Efficient Linear RMSE (Test): 0.026726

Last change: Efficient Linear SVM 5/5 features

2.16 Ensemble RMSE (Test): 0.029878

Last change: Boosted Trees 5/5 features

2.17 Ensemble RMSE (Test): 0.031122

Last change: Bagged Trees 5/5 features

2.18 Gaussian Pr... RMSE (Test): 0.027410

Last change: Squared Exponential GPR 5/5 feature

2.19 Gaussian Pr... RMSE (Test): 0.027015

Last change: Matern 5/2 GPR 5/5 features

2.20 Gaussian Pr... RMSE (Test): 0.026677

Last change: Exponential GPR 5/5 features

2.21 Gaussian Pr... RMSE (Test): 0.026476

Last change: Rational Quadratic GPR 5/5 features

2.22 Neural Network RMSE (Test): 0.86862

Last change: Narrow Neural Network 5/5 features

2.23 Neural Network RMSE (Test): 0.39321

Last change: Medium Neural Network 5/5 features

Summary x

**Model 2.21: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.015786
R-Squared (Validation)	0.61
MSE (Validation)	0.00024921
MAE (Validation)	0.011142
MAPE (Validation)	176.8%
Prediction speed	~15000 obs/sec
Training time	53.407 sec
Model size (Compact)	~54 kB

**Test Results**

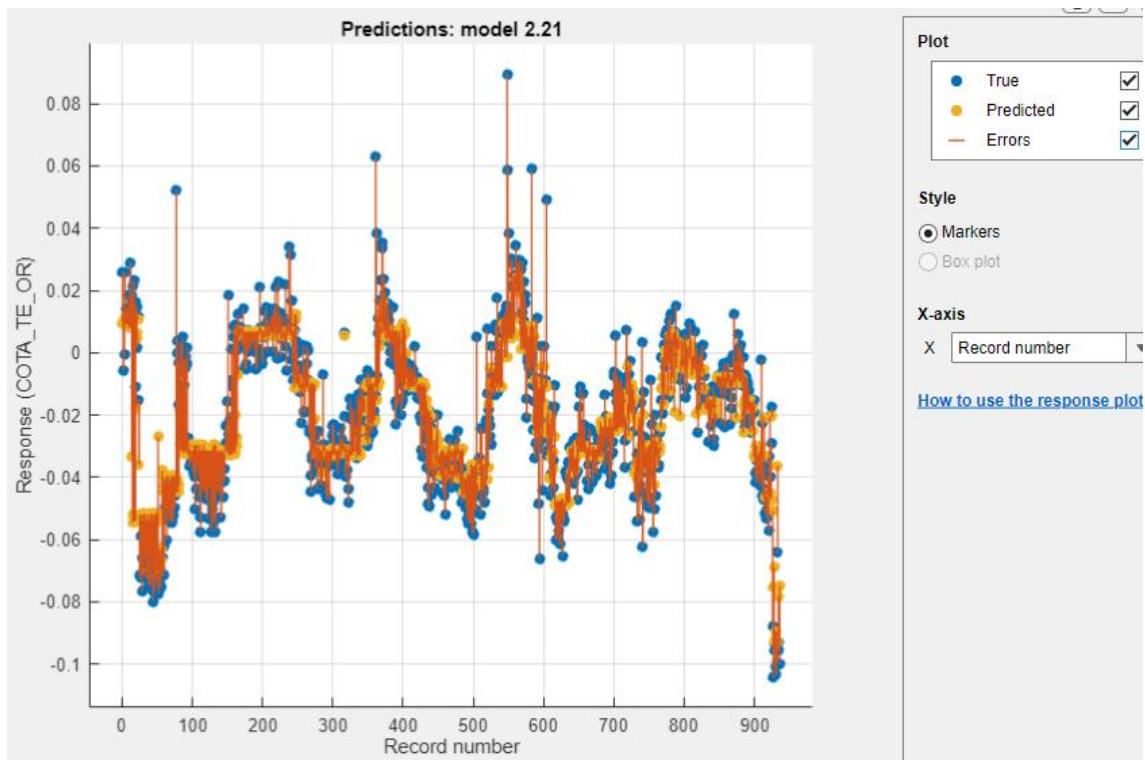
RMSE (Test)	0.026476
R-Squared (Test)	0.01
MSE (Test)	0.00070098
MAE (Test)	0.020620
MAPE (Test)	471.1%

▼ Model Hyperparameters

Preset: Rational Quadratic GPR  
 Basis function: Constant  
 Kernel function: Rational Quadratic  
 Use isotropic kernel: Yes  
 Kernel scale: Automatic  
 Signal standard deviation: Automatic  
 Sigma: Automatic  
 Standardize data: Yes  
 Optimize numeric parameters: Yes

► Feature Selection: 5/5 individual features selected  
 ► PCA: Disabled  
 ► Optimizer: Not applicable

**TABLA 37 MODELOS DE ENTRENAMIENTO DE LOS AROS**



**ILUSTRACIÓN 126 GRÁFICA COMPARATIVA DE LAS PREDICCIÓNES Y DE LOS RESULTADOS REALES EN LOS AROS**

### ENTRENAMIENTO DÍAS 3,4,5 TEST DÍAS 9,10,11

Model Number	Model Type	RMSE (Test)	Last change	Features
2.2	Linear Regression	0.025619	Interactions Linear	5/5 features
2.3	Linear Regression	0.031612	Robust Linear	5/5 features
2.4	Stepwise Linear Regression	0.027989	Stepwise Linear	5/5 features
2.5	Tree	0.023425	Fine Tree	5/5 features
2.6	Tree	0.020840	Medium Tree	5/5 features
2.7	Tree	0.020252	Coarse Tree	5/5 features
2.8	SVM	0.031896	Linear SVM	5/5 features
2.9	SVM	0.023475	Quadratic SVM	5/5 features
2.10	SVM	1.9398	Cubic SVM	5/5 features

**Summary**

**Model 2.6: Tree**  
Status: Tested

**Training Results**

RMSE (Validation)	0.017133
R-Squared (Validation)	0.50
MSE (Validation)	0.00029353
MAE (Validation)	0.012189
MAPE (Validation)	238.0%
Prediction speed	~39000 obs/sec
Training time	8.4637 sec
Model size (Compact)	~29 kB

**Test Results**

RMSE (Test)	0.020840
R-Squared (Test)	0.08
MSE (Test)	0.00043429
MAE (Test)	0.016289
MAPE (Test)	251.3%

**Model Hyperparameters**

- Preset: Medium Tree
- Minimum leaf size: 12
- Surrogate decision splits: Off

**Feature Selection: 5/5 individual features selected**

**PCA: Disabled**

**Optimizer: Not applicable**

**TABLA 38 MODELOS DE ENTRENAMIENTO DE LOS AROS**

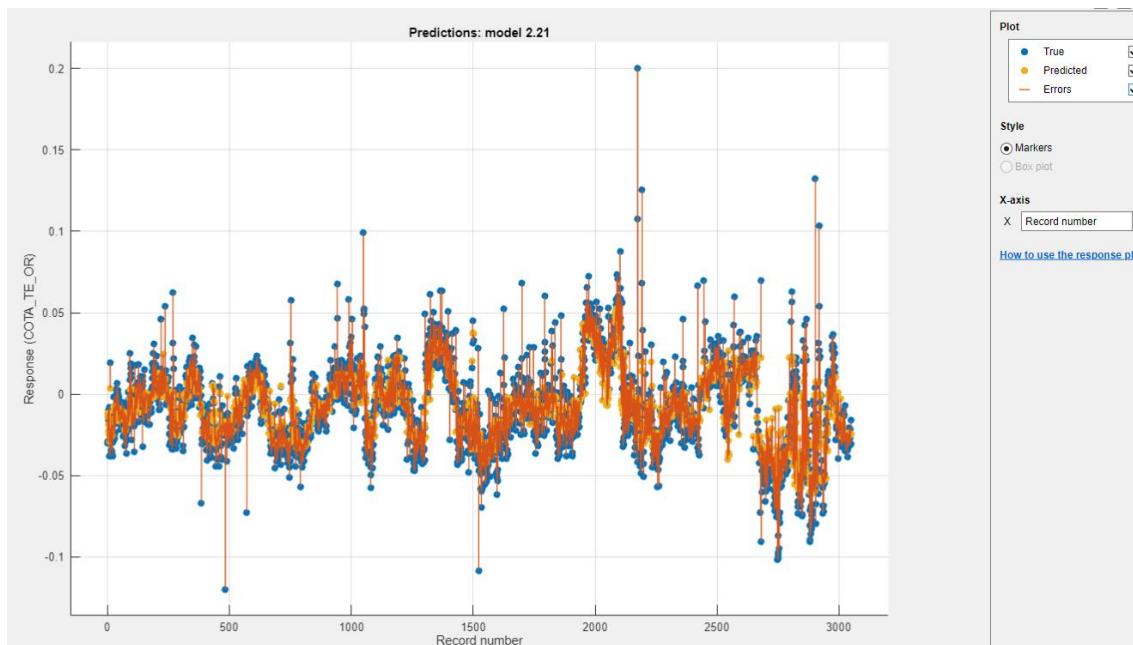


**ILUSTRACIÓN 127 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

## ENTRENAMIENTO DEL 10 AL 16 Y TEST DEL 19 AL 25

Last change: Medium Gaussian SVM	5/5 features	Model 2.21: Gaussian Process Regression
2.13 SVM	RMSE (Test): 0.041166	Status: Tested
Last change: Coarse Gaussian SVM	5/5 features	
2.14 Efficient Linear	RMSE (Test): 0.023593	<b>Training Results</b>
Last change: Efficient Linear Least Squares	5/5 features	RMSE (Validation): 0.017791
2.15 Efficient Linear	RMSE (Test): 0.023860	R-Squared (Validation): 0.54
Last change: Efficient Linear SVM	5/5 features	MSE (Validation): 0.00031654
2.16 Ensemble	RMSE (Test): 0.024554	MAE (Validation): 0.011924
Last change: Boosted Trees	5/5 features	MAPE (Validation): 276.7%
2.17 Ensemble	RMSE (Test): 0.023805	Prediction speed: ~9600 obs/sec
Last change: Bagged Trees	5/5 features	Training time: 569.49 sec
2.18 Gaussian Process Regression	RMSE (Test): 0.024809	Model size (Compact): ~155 kB
Last change: Squared Exponential GPR	5/5 features	
2.19 Gaussian Process Regression	RMSE (Test): 0.023918	<b>Test Results</b>
Last change: Matern 5/2 GPR	5/5 features	RMSE (Test): 0.022404
2.20 Gaussian Process Regression	RMSE (Test): 0.022559	R-Squared (Test): 0.03
Last change: Exponential GPR	5/5 features	MSE (Test): 0.00050192
2.21 Gaussian Process Regression	RMSE (Test): 0.022404	MAE (Test): 0.017188
Last change: Rational Quadratic GPR	5/5 features	MAPE (Test): 196.0%
2.22 Neural Network	RMSE (Test): 0.042918	<b>Model Hyperparameters</b>
Last change: Narrow Neural Network	5/5 features	Preset: Rational Quadratic GPR
2.23 Neural Network	RMSE (Test): 0.082973	Basis function: Constant
Last change: Medium Neural Network	5/5 features	Kernel function: Rational Quadratic
		Use isotropic kernel: Yes
		Kernel scale: Automatic
		Signal standard deviation: Automatic
		Sigma: Automatic
		Standardize data: Yes
		Optimize numeric parameters: Yes
		▶ Feature Selection: 5/5 individual features selected
		▶ PCA: Disabled
		▶ Optimizer: Not applicable

**TABLA 39 MODELOS DE ENTRENAMIENTO DE LOS AROS**

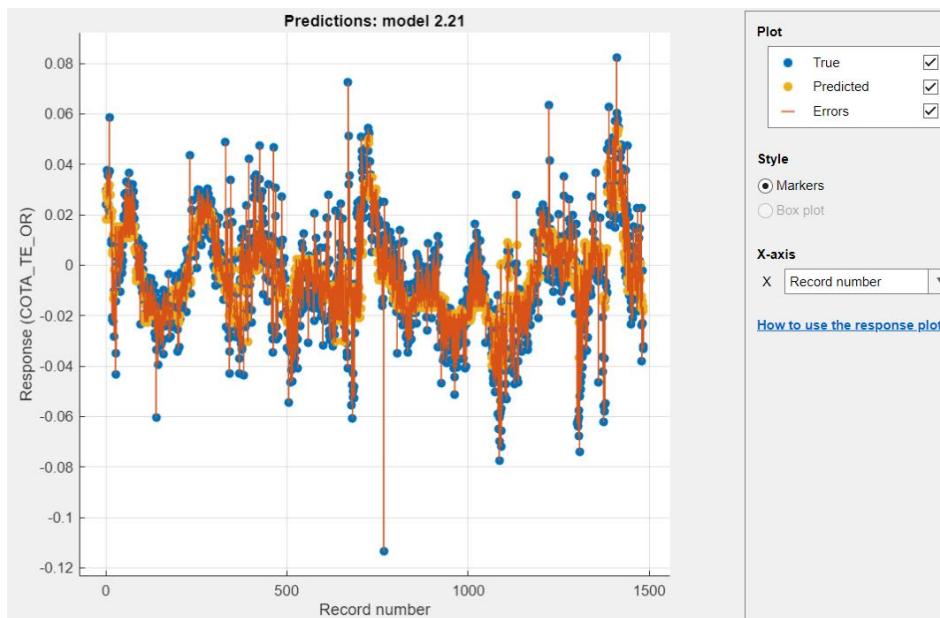


**ILUSTRACIÓN 128 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

### ENTRENAMIENTO DIAS 19,20,21 Y TESTEO DÍAS 22,23,24

2.17 Ensemble	RMSE (Test): 0.040842	<b>Model 2.21: Gaussian Process Regression</b> Status: Tested
Last change: Bagged Trees	5/5 features	
2.18 Gaussian Pr...	RMSE (Test): 0.026271	
Last change: Squared Exponential GPR	5/5 feature	
2.19 Gaussian Pr...	RMSE (Test): 0.025157	
Last change: Matern 5/2 GPR	5/5 features	
2.20 Gaussian Pr...	RMSE (Test): 0.026877	
Last change: Exponential GPR	5/5 features	
2.21 Gaussian Pr...	RMSE (Test): 0.025465	
Last change: Rational Quadratic GPR	5/5 features	
2.22 Neural Net...	RMSE (Test): 1.5033e+12	<b>Training Results</b>
Last change: Narrow Neural Network	5/5 features	RMSE (Validation) 0.016533 R-Squared (Validation) 0.45 MSE (Validation) 0.00027335 MAE (Validation) 0.012016 MAPE (Validation) 229.1% Prediction speed ~9400 obs/sec Training time 207.98 sec Model size (Compact) ~80 kB
2.23 Neural Net...	RMSE (Test): 2.2424e+11	<b>Test Results</b>
Last change: Medium Neural Network	5/5 features	RMSE (Test) 0.025465 R-Squared (Test) -0.10 MSE (Test) 0.00064846 MAE (Test) 0.020110 MAPE (Test) 208.3%
2.24 Neural Net...	RMSE (Test): 1.2017e+12	<b>Model Hyperparameters</b>
Last change: Wide Neural Network	5/5 features	Preset: Rational Quadratic GPR Basis function: Constant Kernel function: Rational Quadratic Use isotropic kernel: Yes Kernel scale: Automatic Signal standard deviation: Automatic Sigma: Automatic Standardize data: Yes Optimize numeric parameters: Yes
2.25 Neural Net...	RMSE (Test): 2.4507e+11	<b>Feature Selection:</b> 5/5 individual features selected
Last change: Bilayered Neural Network	5/5 features	<b>PCA:</b> Disabled
2.26 Neural Net...	RMSE (Test): 1.0810e+11	<b>Optimizer:</b> Not applicable
Last change: Trilayered Neural Network	5/5 feature	
2.27 Kernel	RMSE (Test): 0.030552	
Last change: SVM Kernel	5/5 features	

**TABLA 40 MODELOS DE ENTRENAMIENTO DE LOS AROS**



**ILUSTRACIÓN 129 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

## ENTRENO DÍA 4 Y TEST DÍA 5

Last change: Medium Gaussian SVM 5/5 features	<b>2.13</b> SVM RMSE (Test): 0.052951
Last change: Coarse Gaussian SVM 5/5 features	<b>2.14</b> Efficient Linear RMSE (Test): 0.019490
Last change: Efficient Linear Least Squares 5/5 fea	<b>2.15</b> Efficient Linear RMSE (Test): 0.019594
Last change: Efficient Linear SVM 5/5 features	<b>2.16</b> Ensemble RMSE (Test): 0.026388
Last change: Boosted Trees 5/5 features	<b>2.17</b> Ensemble RMSE (Test): 0.022325
Last change: Bagged Trees 5/5 features	<b>2.18</b> Gaussian Pr... RMSE (Test): 0.019017
Last change: Squared Exponential GPR 5/5 feature	<b>2.19</b> Gaussian Pr... RMSE (Test): 0.018955
Last change: Matern 5/2 GPR 5/5 features	<b>2.20</b> Gaussian Pr... RMSE (Test): 0.021778
Last change: Exponential GPR 5/5 features	<b>2.21</b> Gaussian Pr... RMSE (Test): 0.021230
Last change: Rational Quadratic GPR 5/5 features	<b>2.22</b> Neural Network RMSE (Test): 0.064527
Last change: Narrow Neural Network 5/5 features	<b>2.23</b> Neural Network RMSE (Test): 0.19450
Last change: Medium Neural Network 5/5 features	

**Model 2.19: Gaussian Process Regression**  
Status: Tested

**Training Results**

RMSE (Validation)	0.016559
R-Squared (Validation)	0.61
MSE (Validation)	0.00027420
MAE (Validation)	0.011853
MAPE (Validation)	215.7%
Prediction speed	~13000 obs/sec
Training time	35.335 sec
Model size (Compact)	~68 kB

**Test Results**

RMSE (Test)	0.018955
R-Squared (Test)	0.02
MSE (Test)	0.00035928
MAE (Test)	0.014650
MAPE (Test)	263.8%

**Model Hyperparameters**

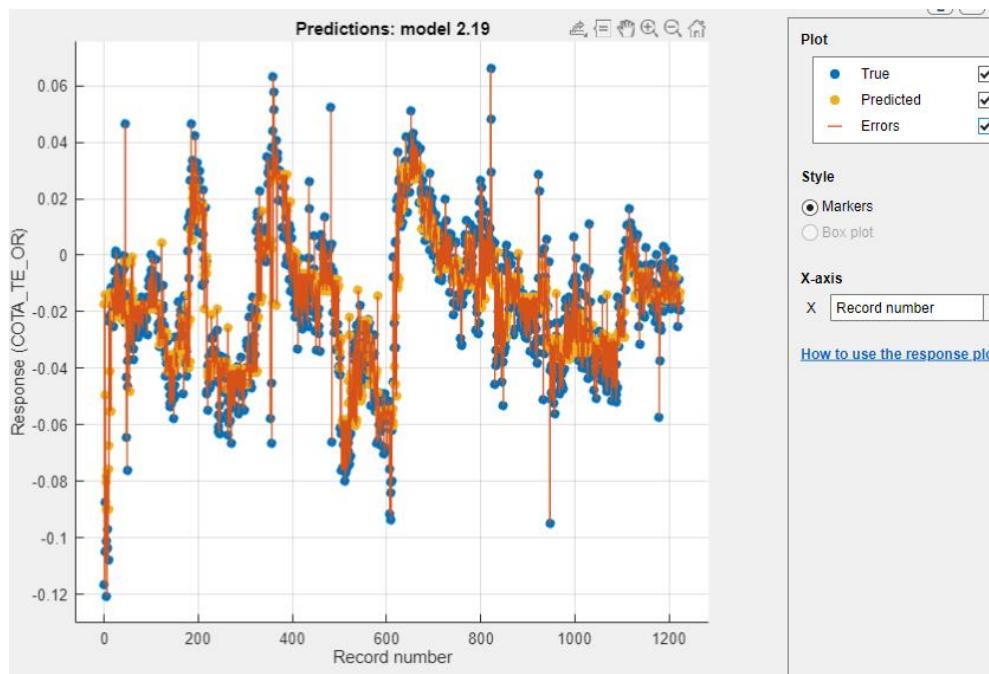
- Preset: Matern 5/2 GPR
- Basis function: Constant
- Kernel function: Matern 5/2
- Use isotropic kernel: Yes
- Kernel scale: Automatic
- Signal standard deviation: Automatic
- Sigma: Automatic
- Standardize data: Yes
- Optimize numeric parameters: Yes

► Feature Selection: 5/5 individual features selected

► PCA: Disabled

► Optimizer: Not applicable

**TABLA 41 MODELOS DE ENTRENAMIENTO DE LOS AROS**

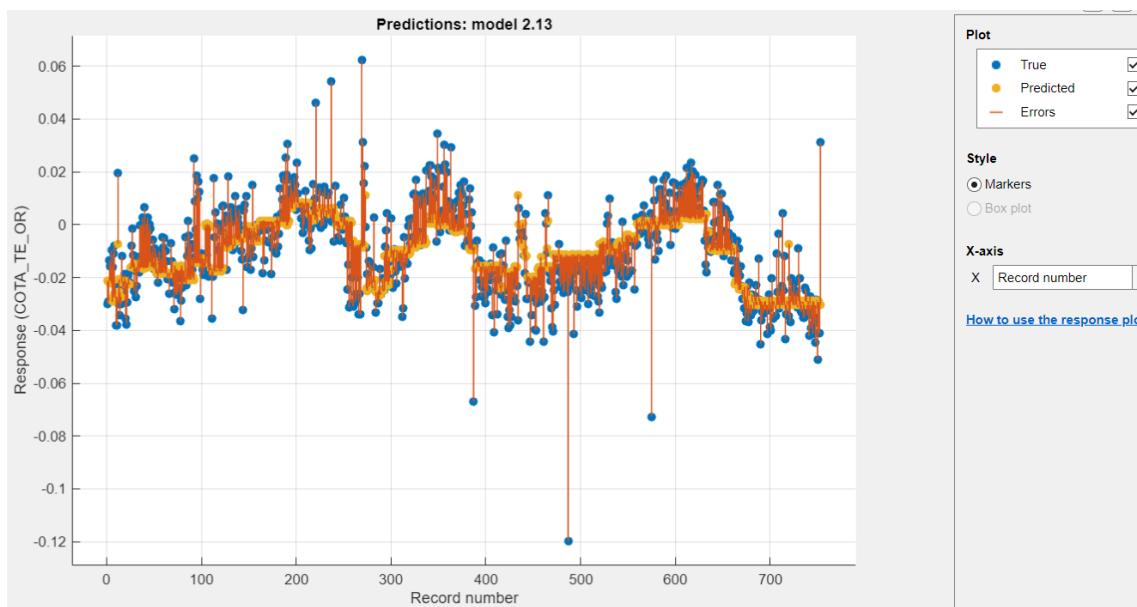


**ILUSTRACIÓN 130 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

### ENTRENAMIENTO DIA 10 Y TESTEO DÍA 11

<b>2.8</b> SVM	RMSE (Test): 0.019281	<b>Model 2.13: SVM</b> Status: Tested
Last change: Linear SVM	5/5 features	
<b>2.9</b> SVM	RMSE (Test): 0.15958	
Last change: Quadratic SVM	5/5 features	
<b>2.10</b> SVM	RMSE (Test): 14.804	
Last change: Cubic SVM	5/5 features	
<b>2.11</b> SVM	RMSE (Test): 0.025078	
Last change: Fine Gaussian SVM	5/5 features	
<b>2.12</b> SVM	RMSE (Test): 0.030098	
Last change: Medium Gaussian SVM	5/5 features	
<b>2.13</b> SVM	RMSE (Test): 0.019276	<b>Training Results</b> RMSE (Validation) 0.013904 R-Squared (Validation) 0.39 MSE (Validation) 0.00019331 MAE (Validation) 0.010320 MAPE (Validation) 668.4% Prediction speed ~10000 obs/sec Training time 5.522 sec Model size (Compact) ~35 kB
Last change: Coarse Gaussian SVM	5/5 features	<b>Test Results</b> RMSE (Test) 0.019276 R-Squared (Test) 0.34 MSE (Test) 0.00037158 MAE (Test) 0.014148 MAPE (Test) 221.1%
<b>2.14</b> Efficient Linear	RMSE (Test): 0.024694	<b>Model Hyperparameters</b> Preset: Coarse Gaussian SVM Kernel function: Gaussian Kernel scale: 8.9 Box constraint: Automatic Epsilon: Auto Standardize data: Yes
Last change: Efficient Linear Least Squares	5/5 features	
<b>2.15</b> Efficient Linear	RMSE (Test): 0.024897	
Last change: Efficient Linear SVM	5/5 features	
<b>2.16</b> Ensemble	RMSE (Test): 0.022747	

**TABLA 42 MODELOS DE ENTRENAMIENTO DE LOS AROS**

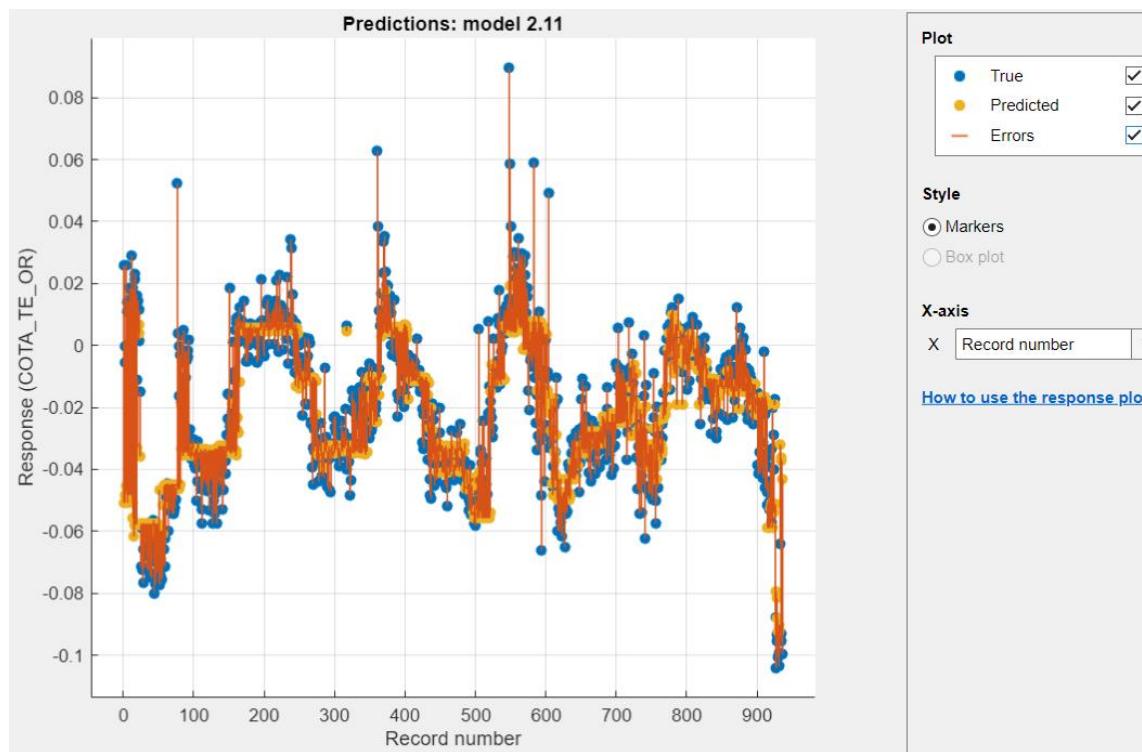


**ILUSTRACIÓN 131 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

## ENTRENAMIENTO DIA 3 Y TESTEO DIA 4

2.9 SVM	RMSE (Test): 0.51825	<b>Model 2.11: SVM</b> Status: Tested  <b>Training Results</b> RMSE (Validation) 0.018437 R-Squared (Validation) 0.47 MSE (Validation) 0.00033994 MAE (Validation) 0.012529 MAPE (Validation) 205.6% Prediction speed ~25000 obs/sec Training time 1.2693 sec Model size (Compact) ~40 kB  <b>Test Results</b> RMSE (Test) 0.026383 R-Squared (Test) 0.02 MSE (Test) 0.00069609 MAE (Test) 0.020625 MAPE (Test) 414.0%  <b>Model Hyperparameters</b> Preset: Fine Gaussian SVM Kernel function: Gaussian Kernel scale: 0.56 Box constraint: Automatic Epsilon: Auto Standardize data: Yes
2.10 SVM	RMSE (Test): 3.2144	
2.11 SVM	RMSE (Test): 0.026383	
2.12 SVM	RMSE (Test): 0.026991	
2.13 SVM	RMSE (Test): 0.049048	
2.14 Efficient Linear	RMSE (Test): 0.026767	
2.15 Efficient Linear	RMSE (Test): 0.026726	
2.16 Ensemble	RMSE (Test): 0.029878	
2.17 Ensemble	RMSE (Test): 0.031122	
2.18 Gaussian Pr...	RMSE (Test): 0.027410	

**TABLA 43 MODELOS DE ENTRENAMIENTO DE LOS AROS**



**ILUSTRACIÓN 132 GRÁFICA COMPARATIVA DE LAS PREDICCIONES Y DE LOS RESULTADOS REALES EN LOS AROS**

## ANEXO 5 GEMELO DIGITAL

### GD CON DATOS DE PARTIDA

#### ESTRATEGIA DE EMPAREJADO

#### SOLO EMPAREJADO RECTO PERMITIDO

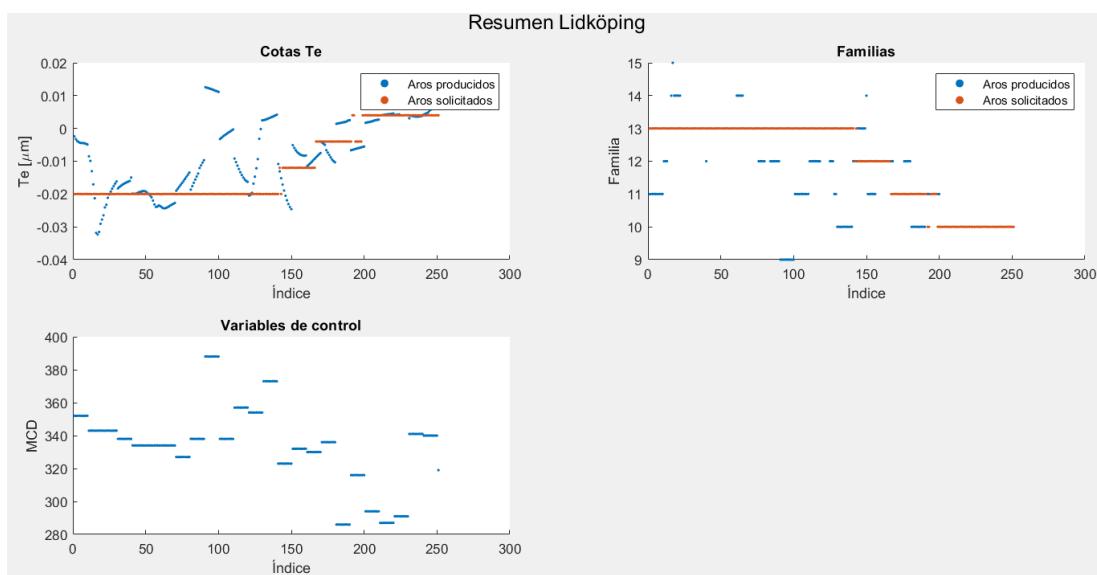
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 0;
estrategia_emparejado.V = 0;

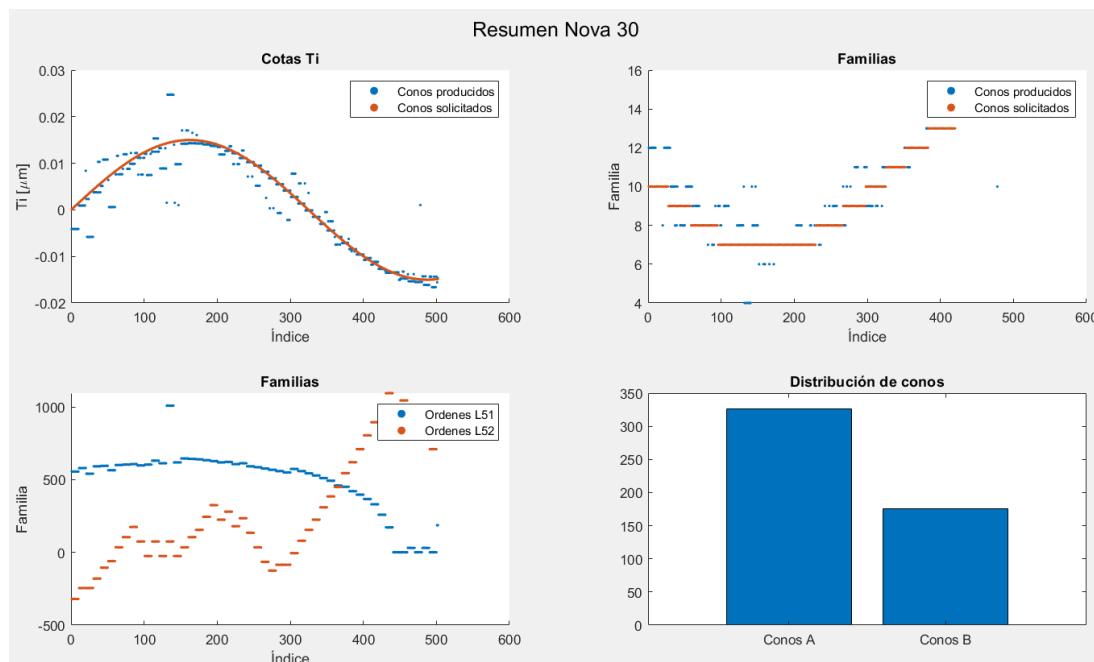
grabar_videos = 0;
mostrar_figuras = 1;

```

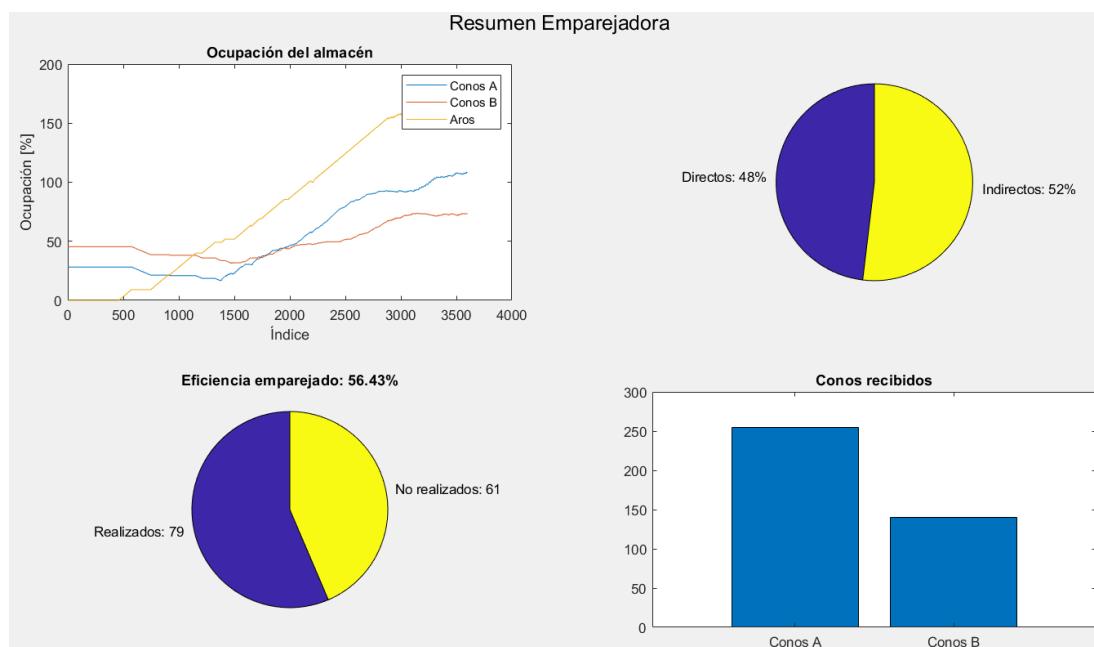
#### ILUSTRACIÓN 133 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL



#### ILUSTRACIÓN 134 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN



**ILUSTRACIÓN 135 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**



**ILUSTRACIÓN 136 RESULTADO DE LA SIMULACIÓN**

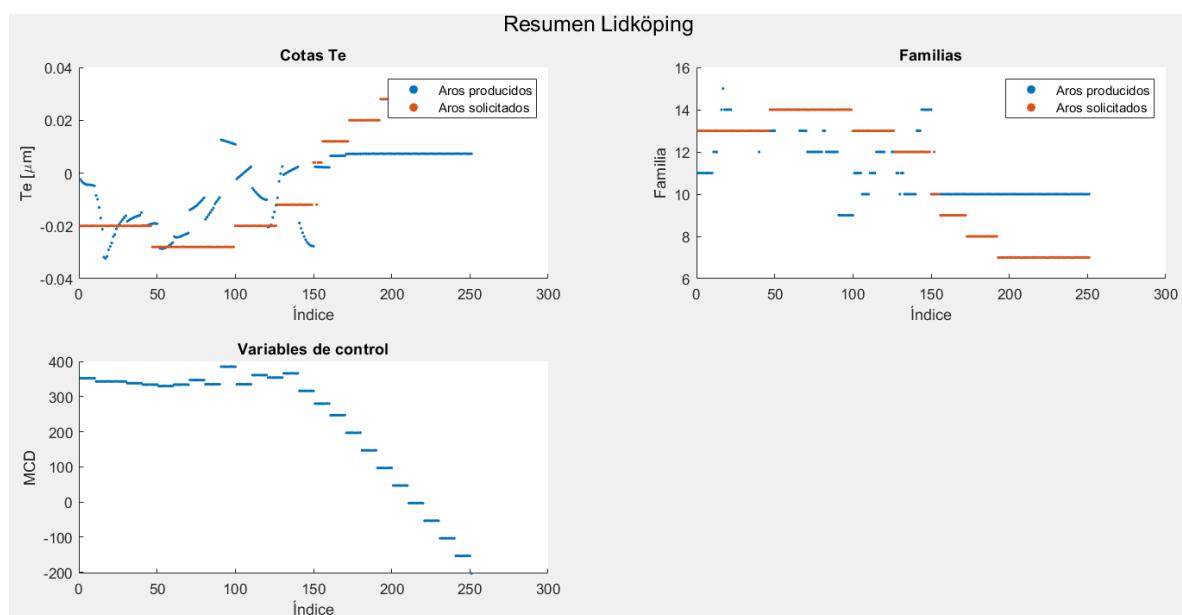
**EMPAREJADO RECTO Y EMPAREJADO EN L**

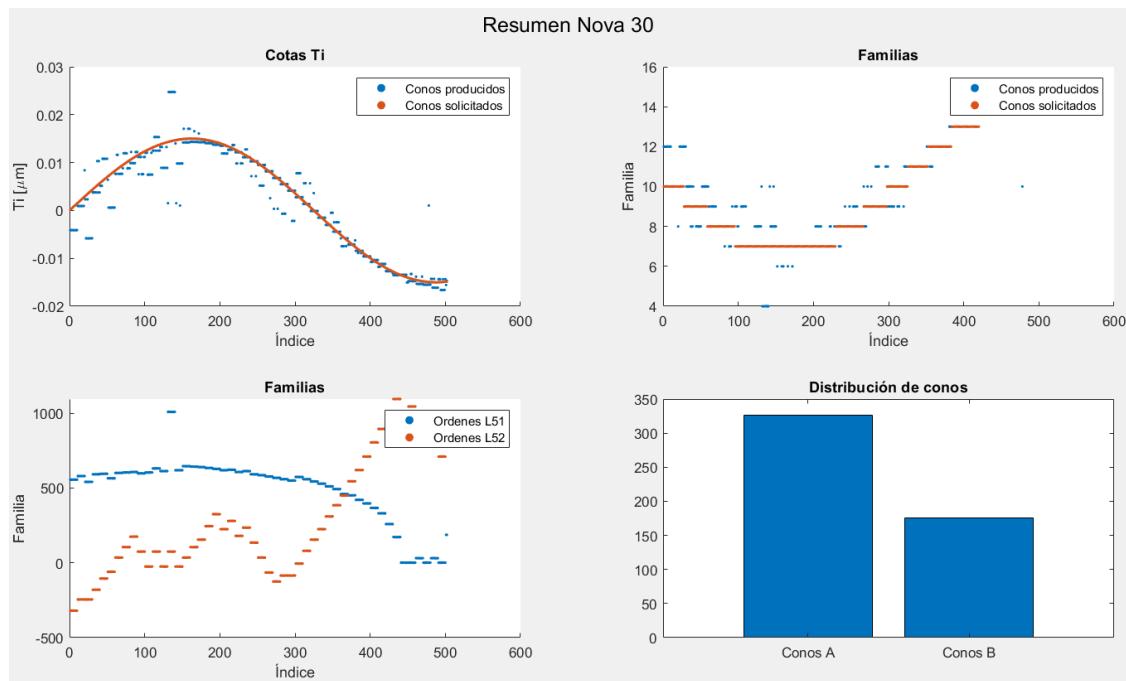
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 0;

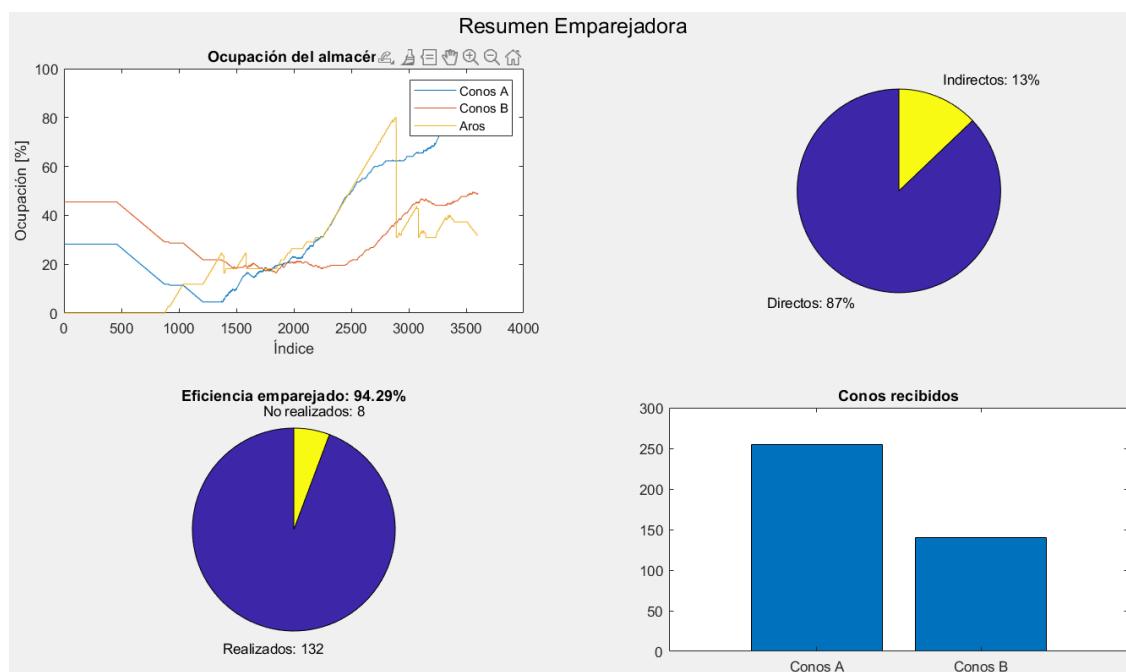
grabar_videos = 0;
mostrar_figuras = 1;

```

**ILUSTRACIÓN 137 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL****ILUSTRACIÓN 138 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**



**ILUSTRACIÓN 139 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**



**ILUSTRACIÓN 140 RESULTADO DE LA SIMULACIÓN**

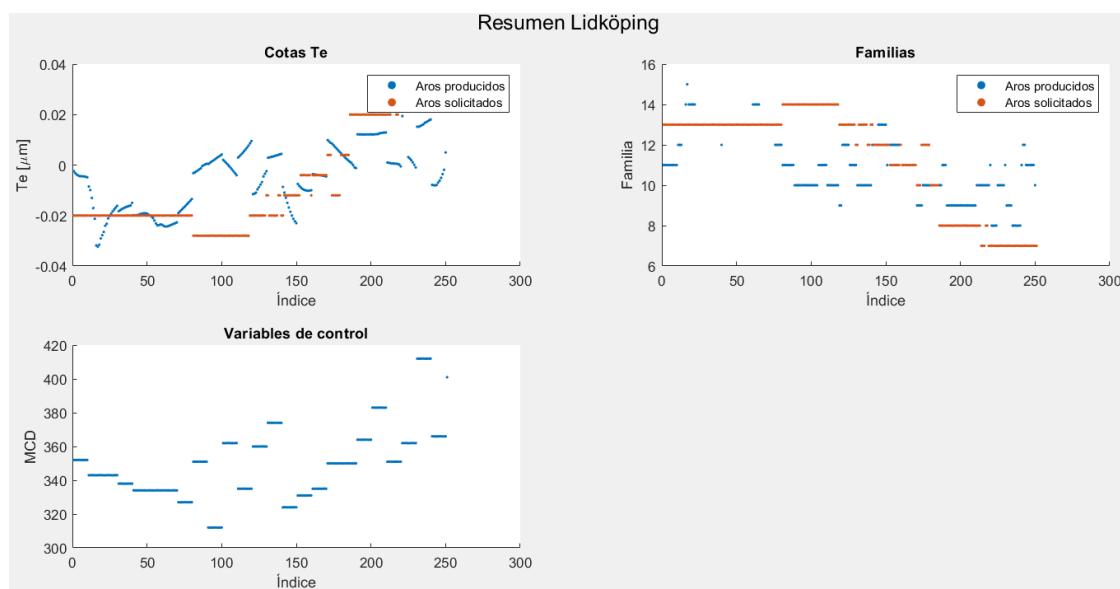
**EMPAREJADO RECTO Y EN V**

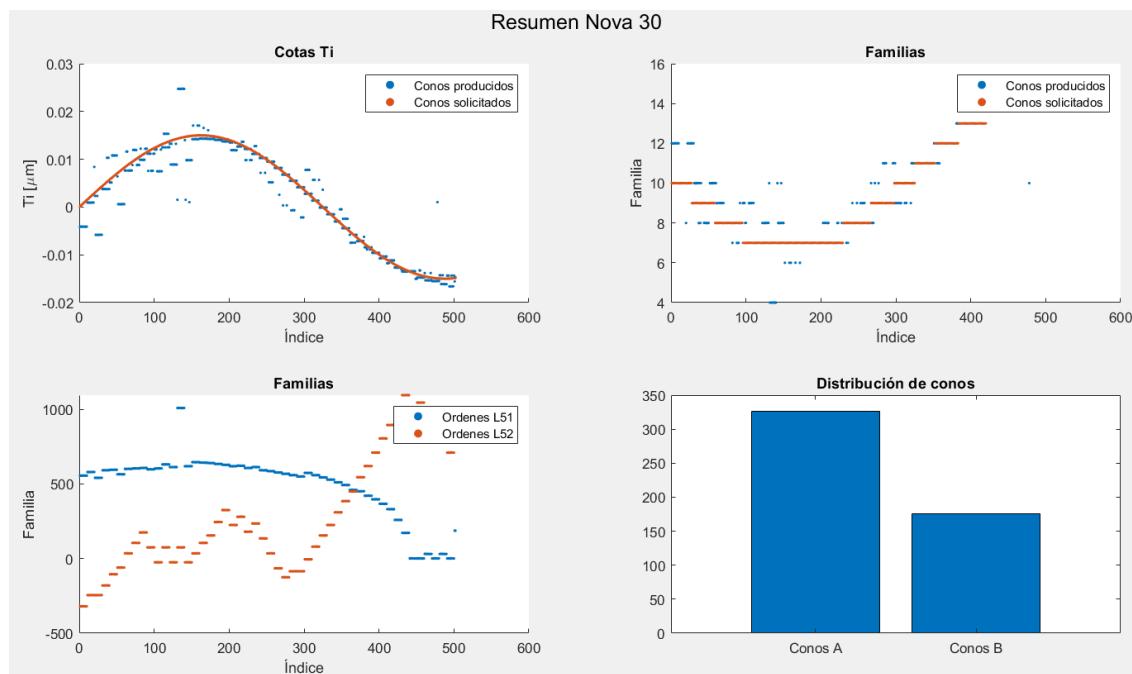
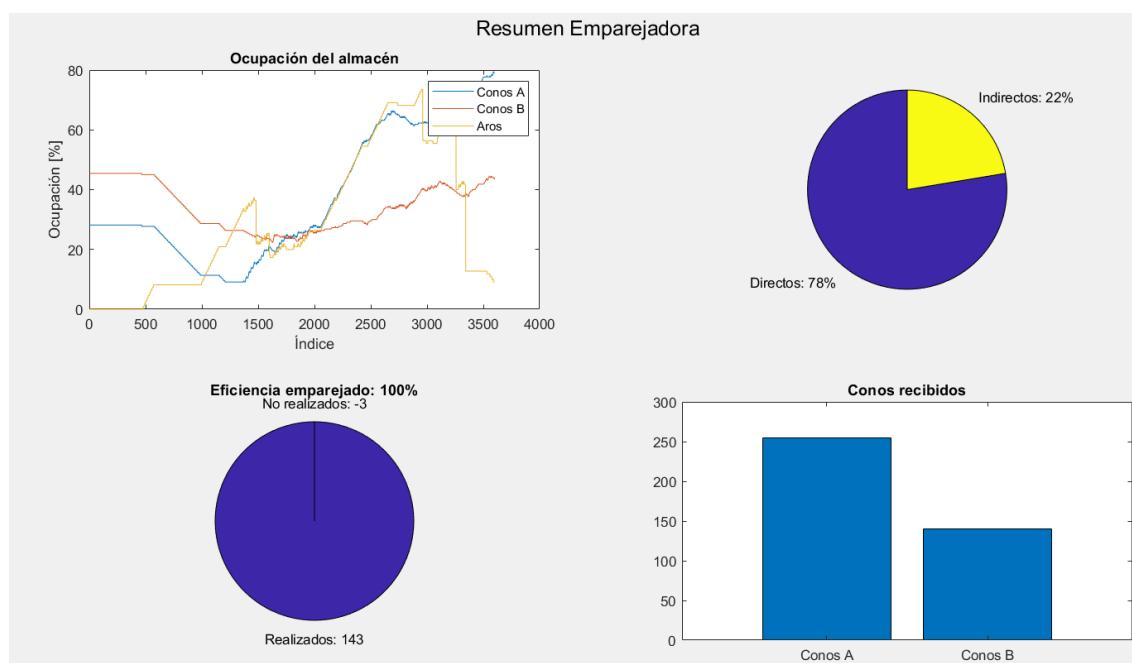
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 0;
estrategia_emparejado.V = 1;

grabar_videos = 0;
mostrar_figuras = 1;

```

**ILUSTRACIÓN 141 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL****ILUSTRACIÓN 142 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

**ILUSTRACIÓN 143 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 144 RESULTADO DE LA SIMULACIÓN**

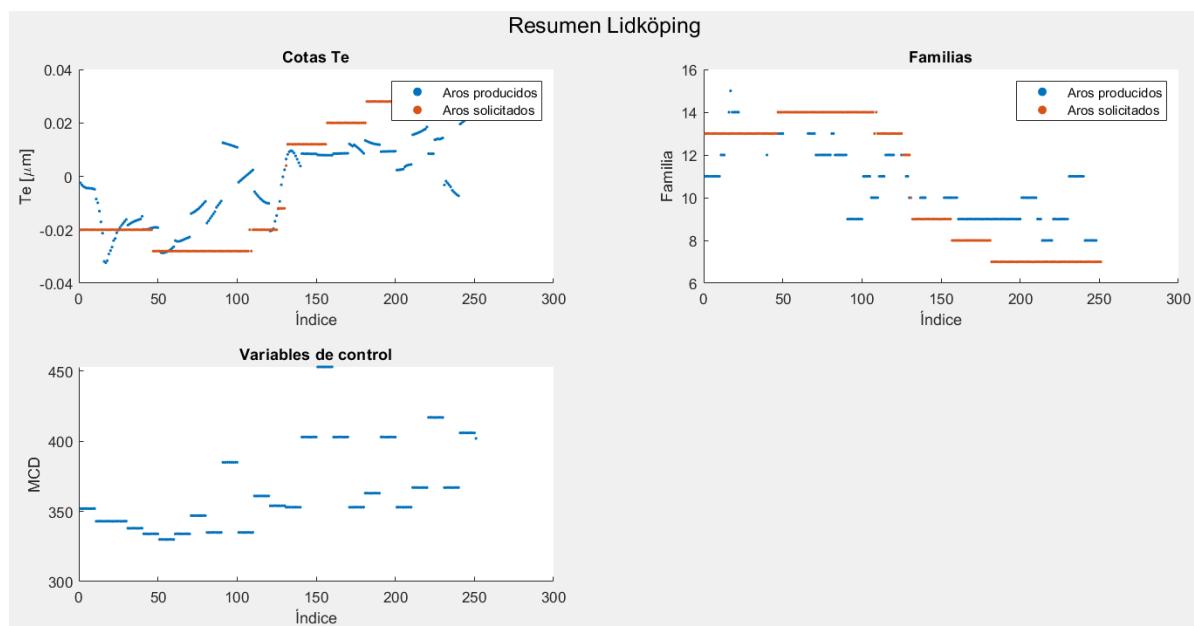
**EMPAREJADO EN L Y EN V**

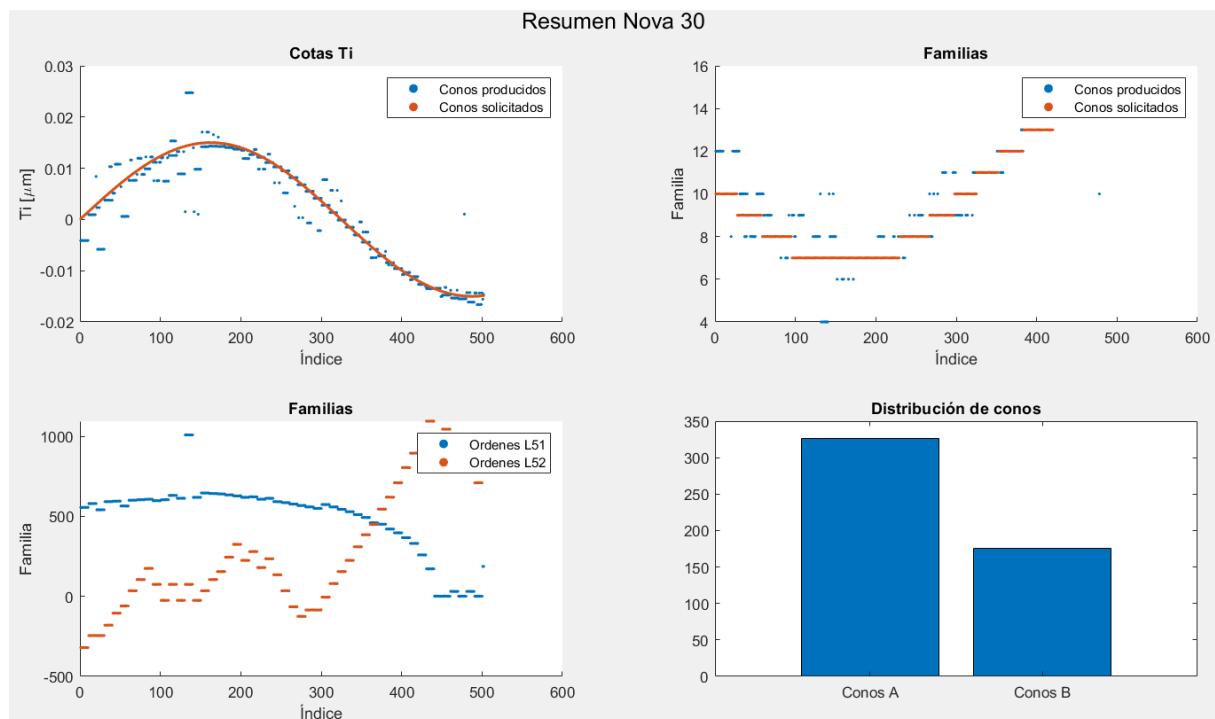
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 0;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

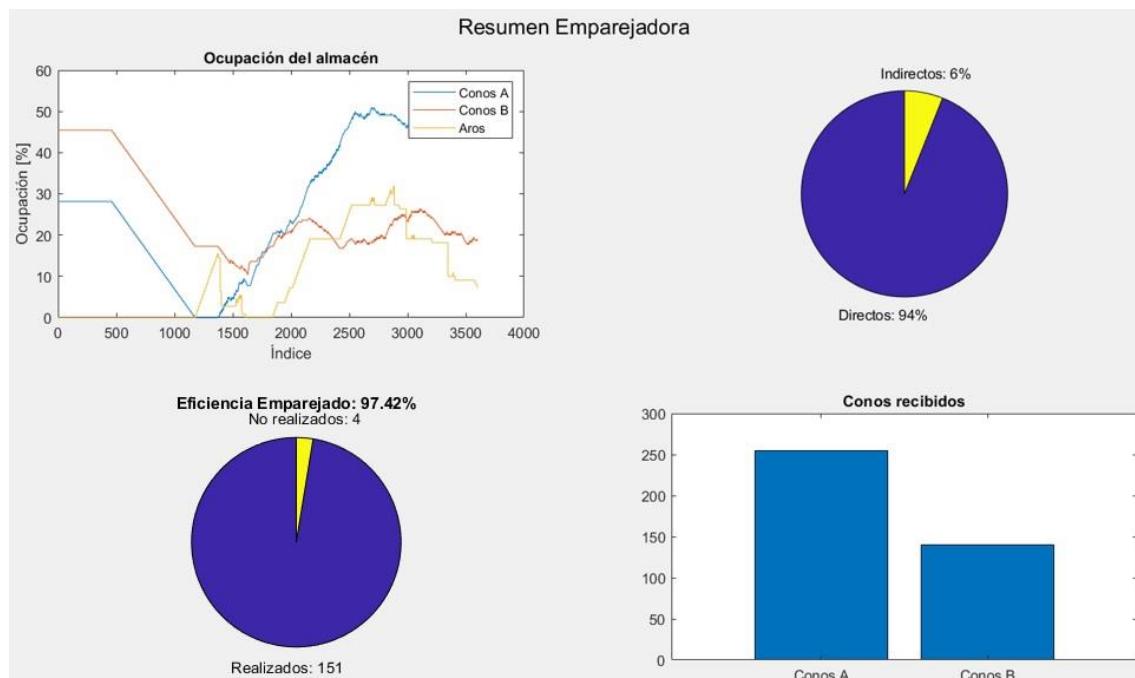
grabar_videos = 0;
mostrar_figuras = 1;

```

**ILUSTRACIÓN 145 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL****ILUSTRACIÓN 146 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**



**ILUSTRACIÓN 147 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**



**ILUSTRACIÓN 148 RESULTADO DE LA SIMULACIÓN**

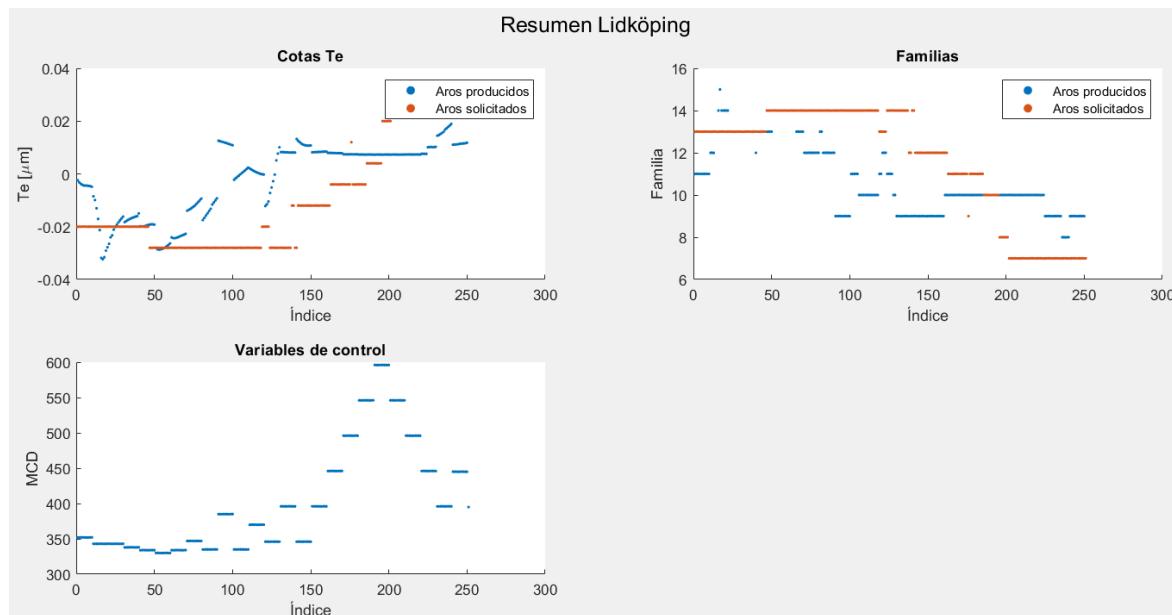
**SOLO EMPAREJADO EN L**

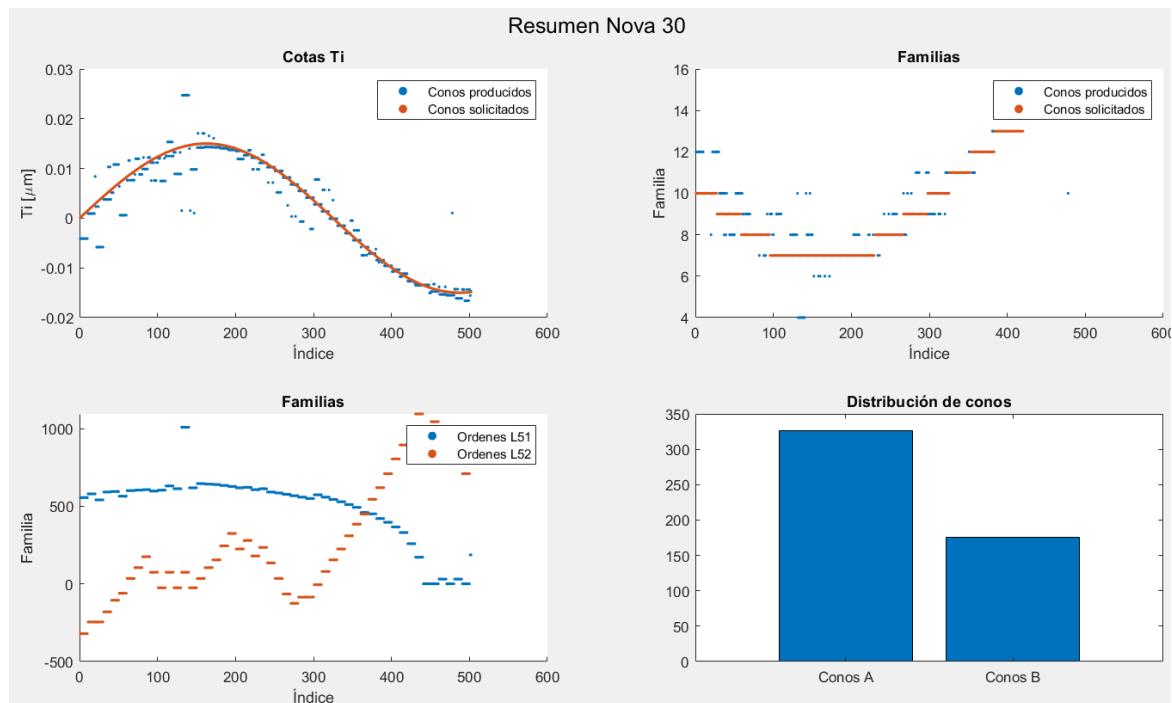
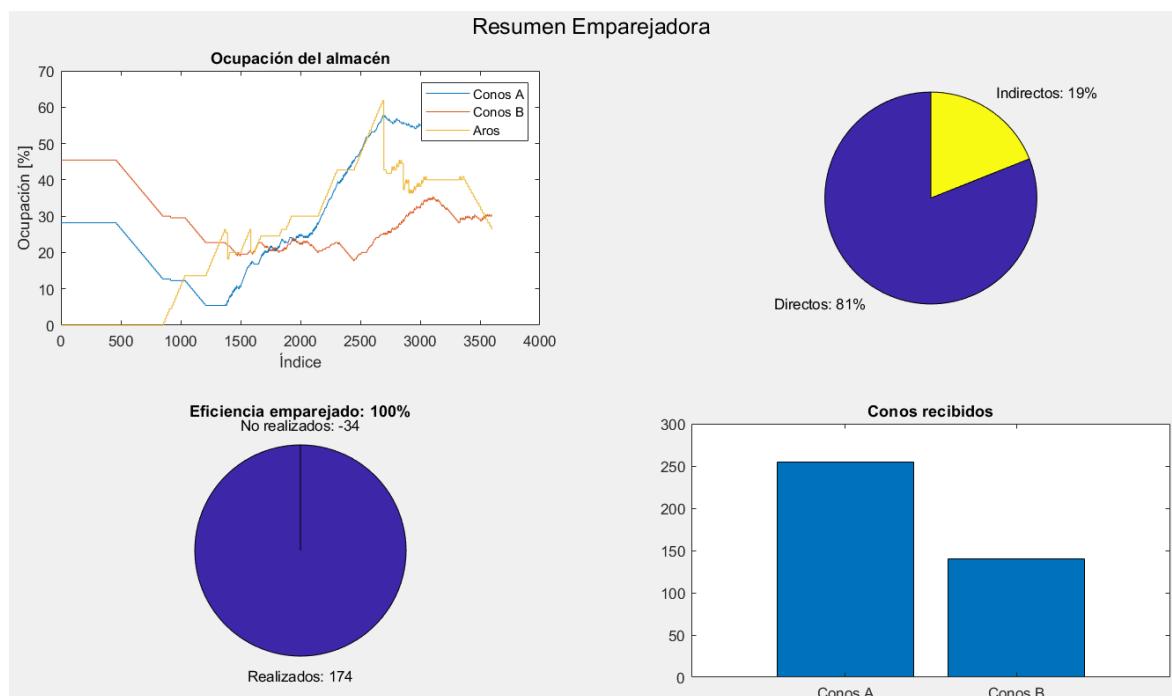
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 0;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 0;

grabar_videos = 0;
mostrar_figuras = 1;

```

**ILUSTRACIÓN 149 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL****ILUSTRACIÓN 150 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

**ILUSTRACIÓN 151 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 152 RESULTADO DE LA SIMULACIÓN**

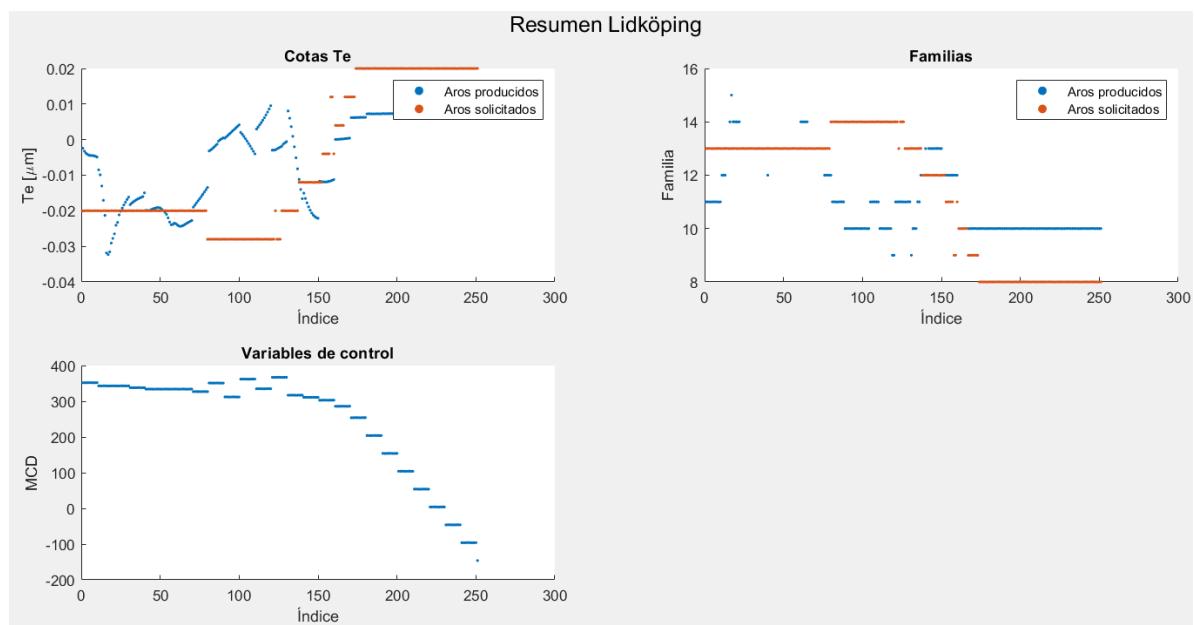
**SOLO EMPAREJADO EN V**

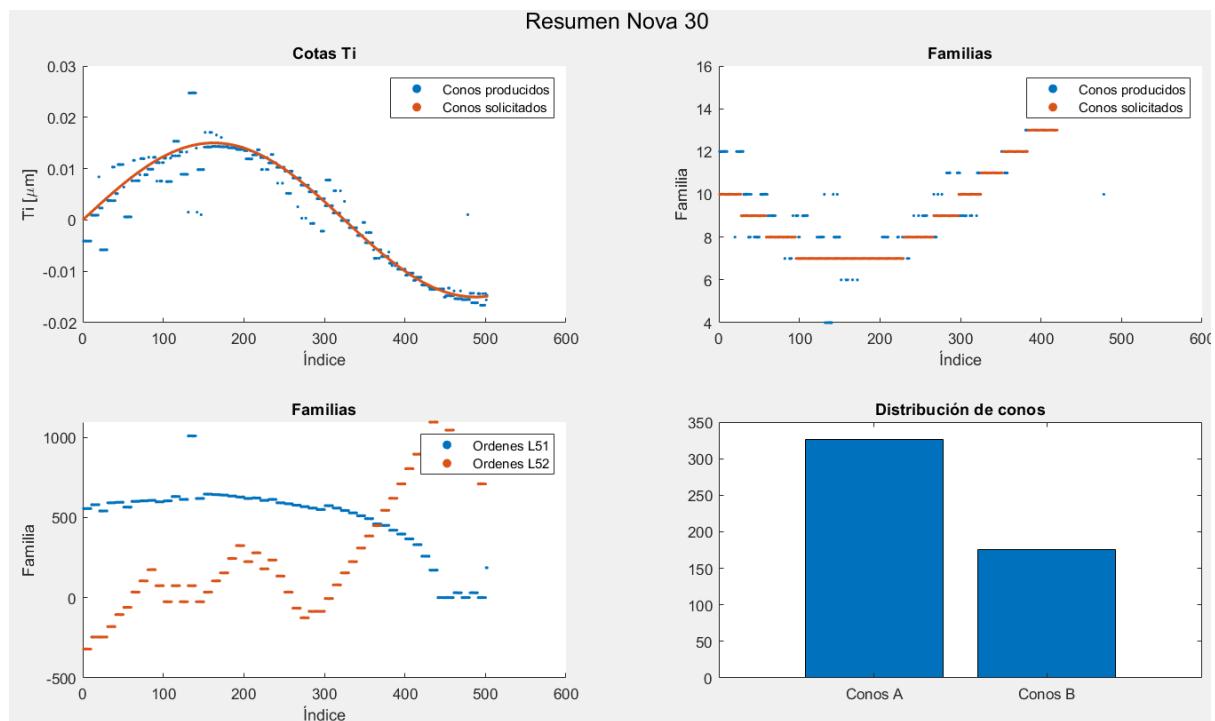
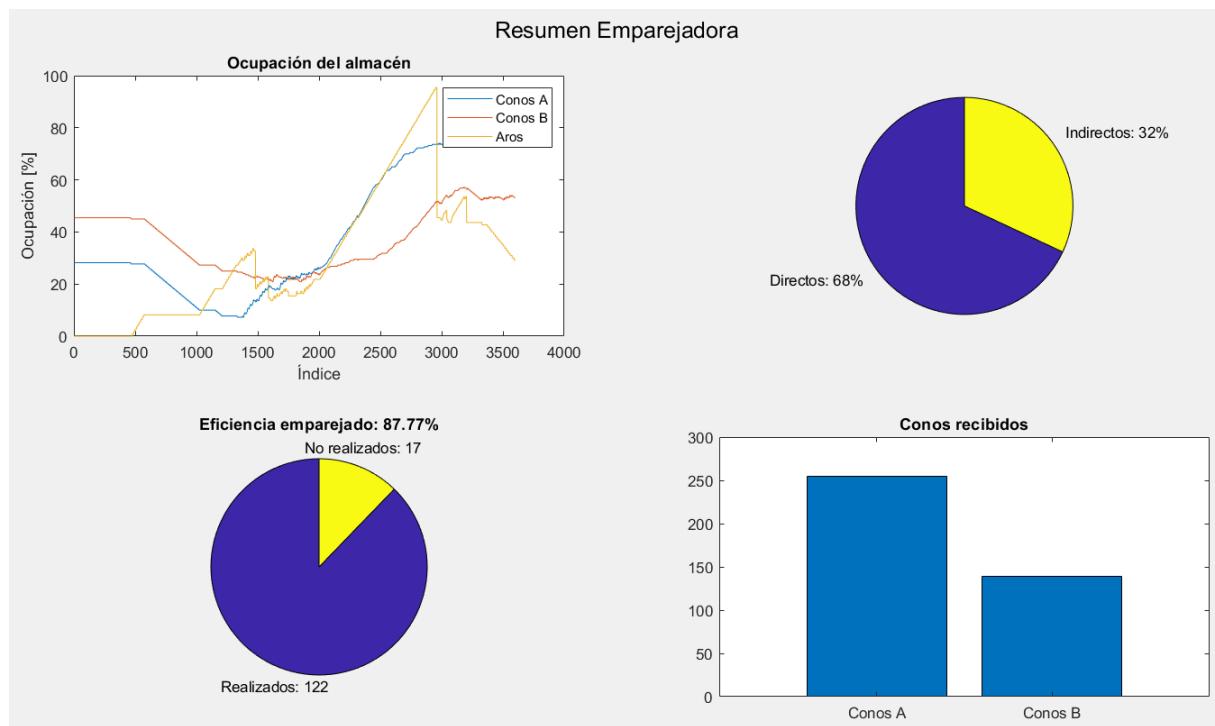
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 0;
estrategia_emparejado.L = 0;
estrategia_emparejado.V = 1;

grabar_videos = 0;
mostrar_figuras = 1;

```

**ILUSTRACIÓN 153 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL****ILUSTRACIÓN 154 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

**ILUSTRACIÓN 155 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 156 RESULTADO DE LA SIMULACIÓN**

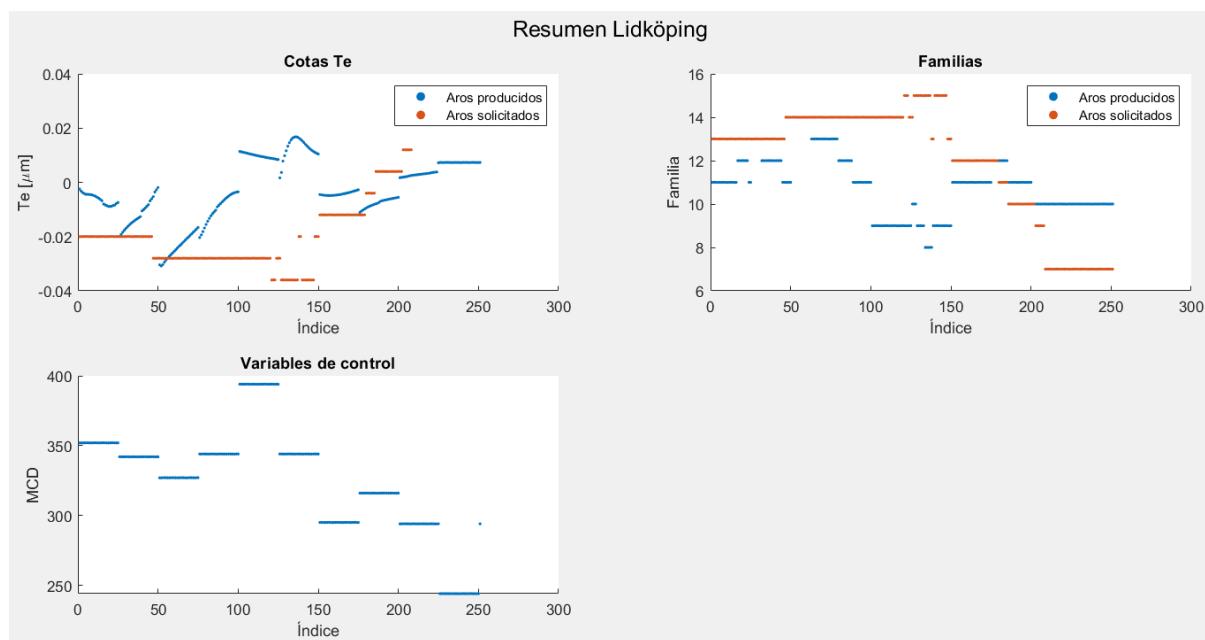
**CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25**

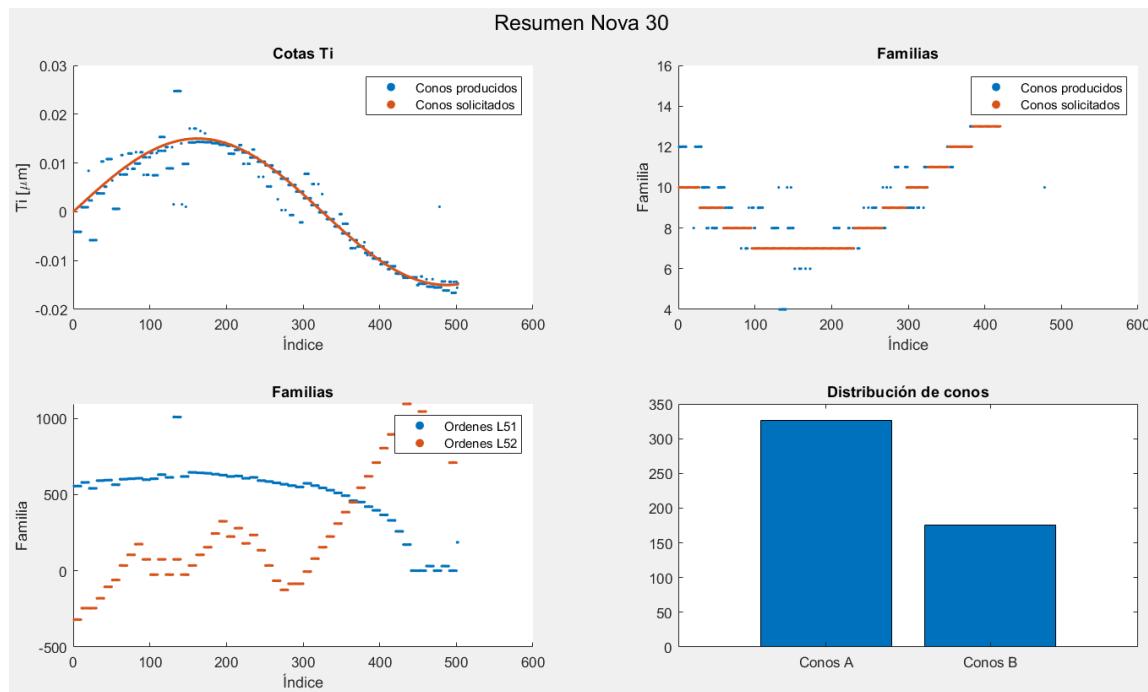
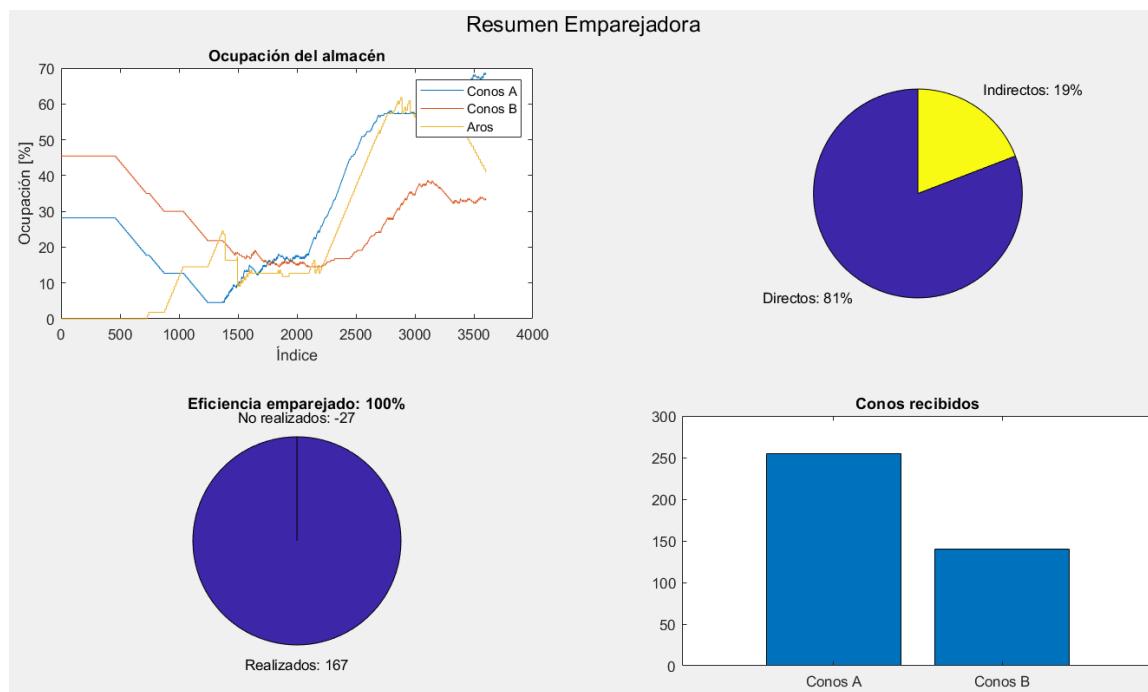
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 25;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

grabar_videos = 0;
mostrar_figuras = 1;

```

**ILUSTRACIÓN 157 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL****ILUSTRACIÓN 158 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

**ILUSTRACIÓN 159 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 160 RESULTADO DE LA SIMULACIÓN**

## CAMBIO EN EL NUMERO DE FACTORES

### 7 FACTORES

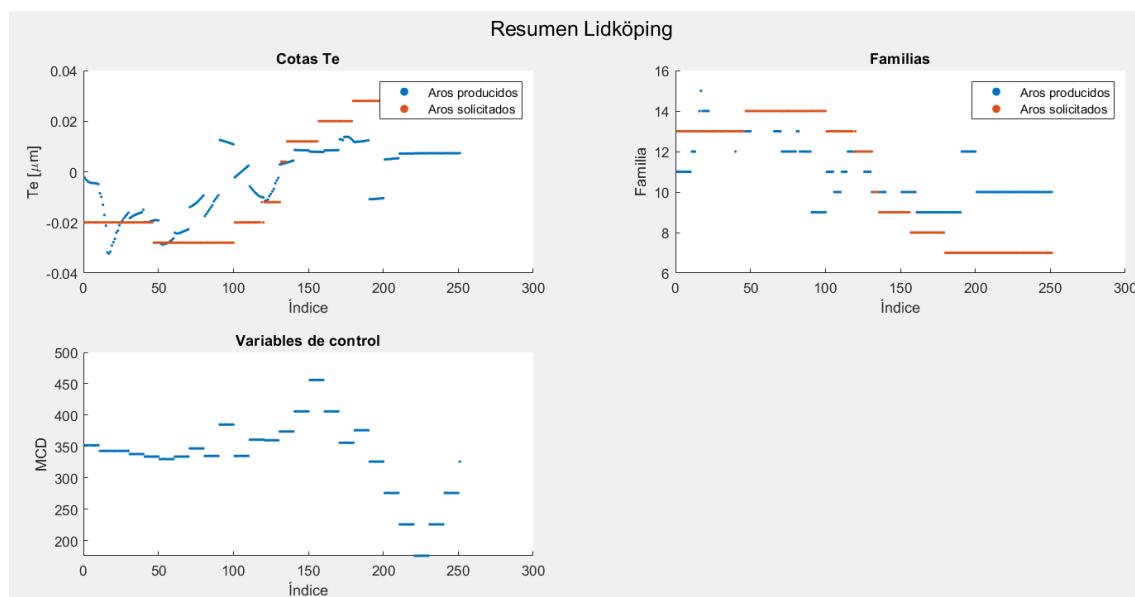
```

numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

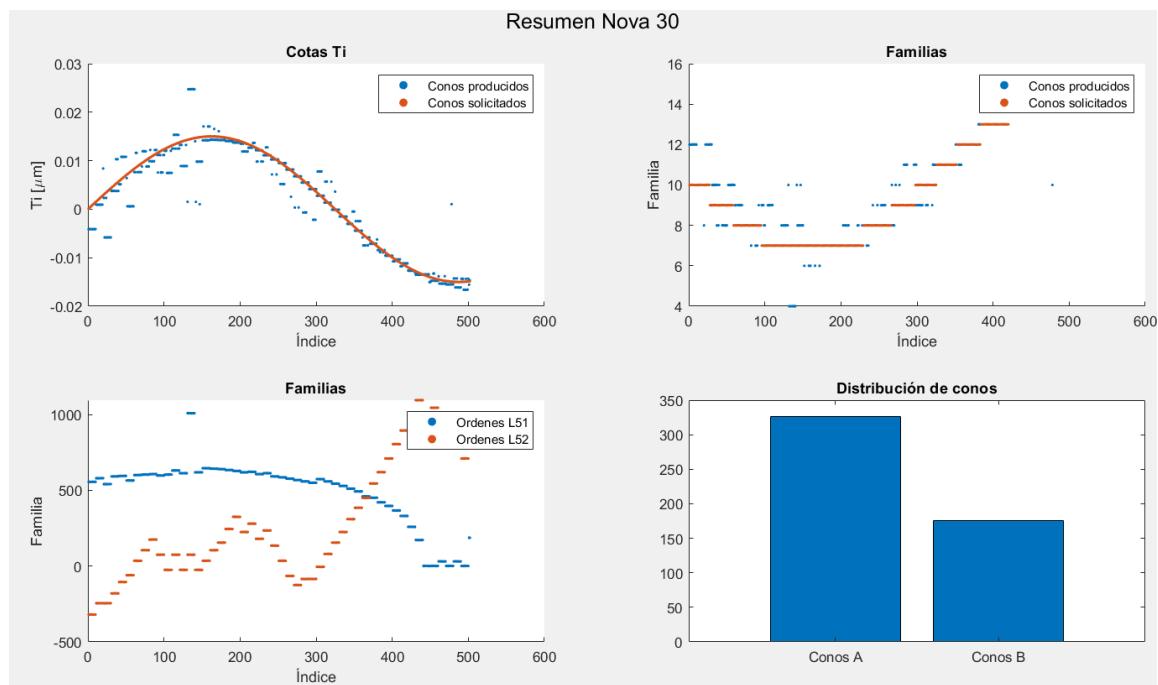
grabar_videos = 0;
mostrar_figuras = 1;

```

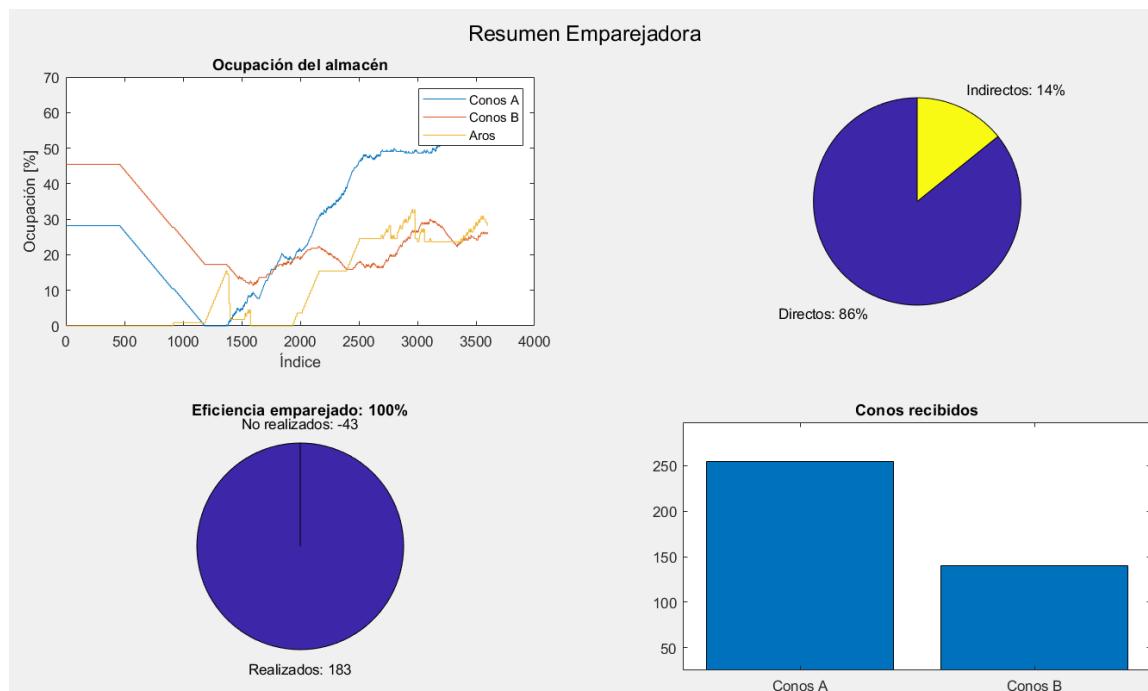
### ILUSTRACIÓN 161 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL



### ILUSTRACIÓN 162 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN



**ILUSTRACIÓN 163 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**



**ILUSTRACIÓN 164 RESULTADO DE LA SIMULACIÓN**

#### 4 FACTORES

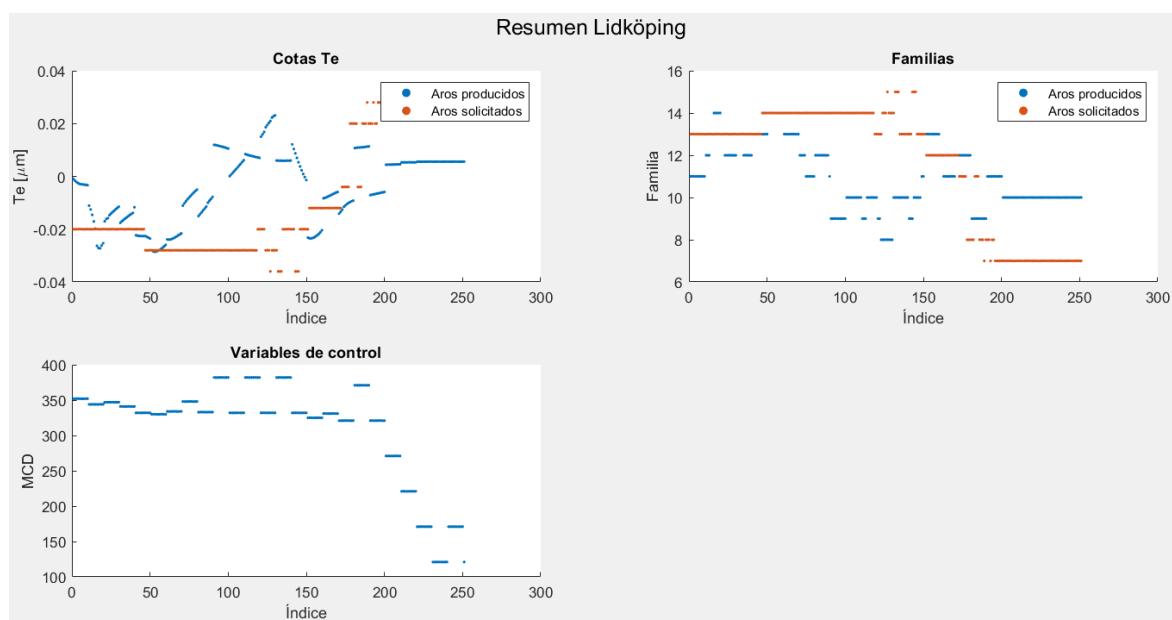
```

numero_factores_M06 = 4;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

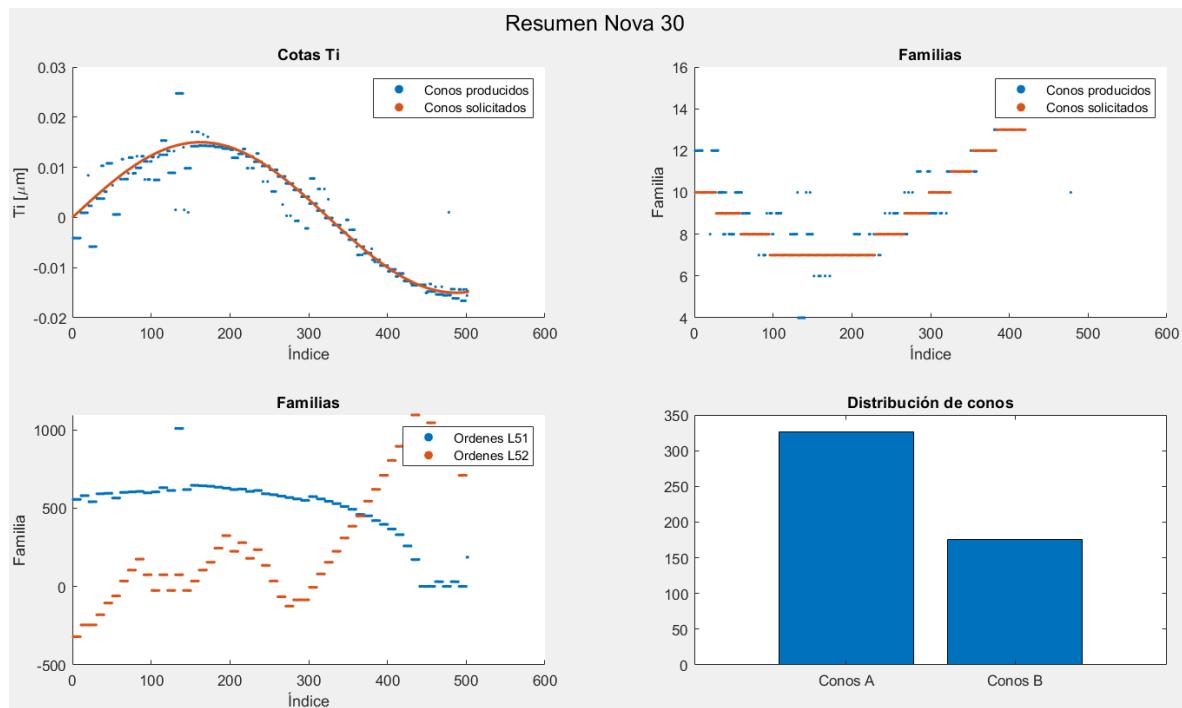
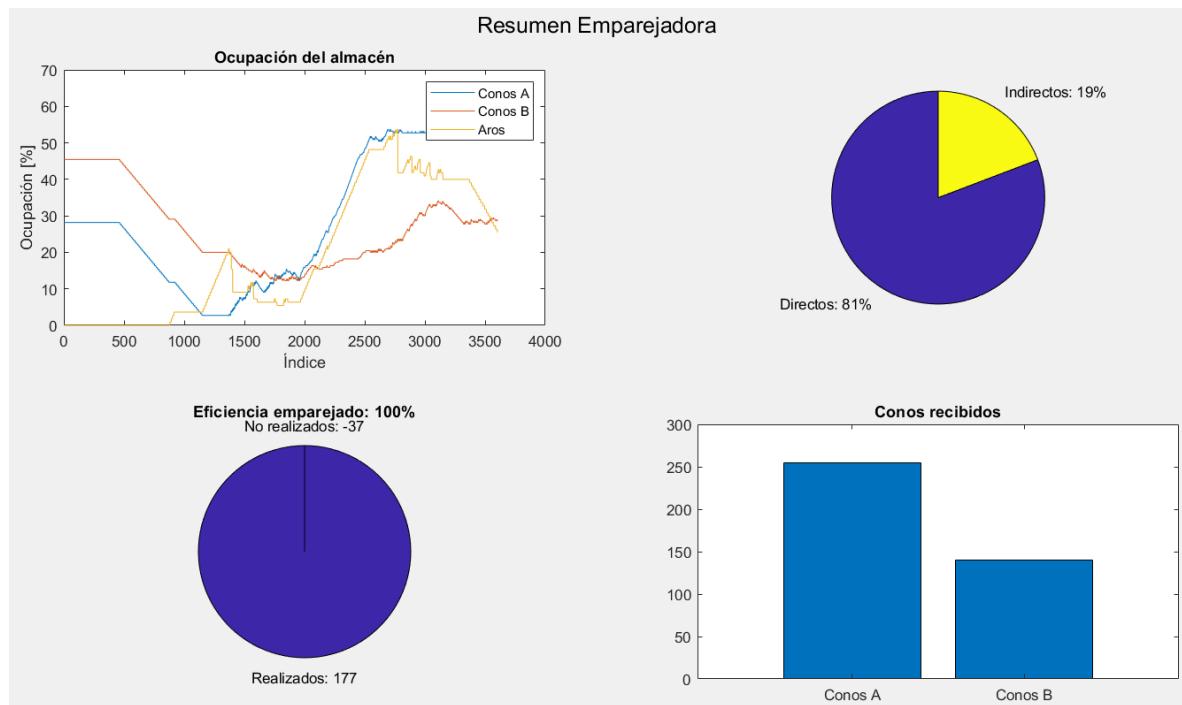
grabar_videos = 0;
mostrar_figuras = 1;

```

#### ILUSTRACIÓN 165 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL



#### ILUSTRACIÓN 166 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN

**ILUSTRACIÓN 167 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 168 RESULTADO DE LA SIMULACIÓN**

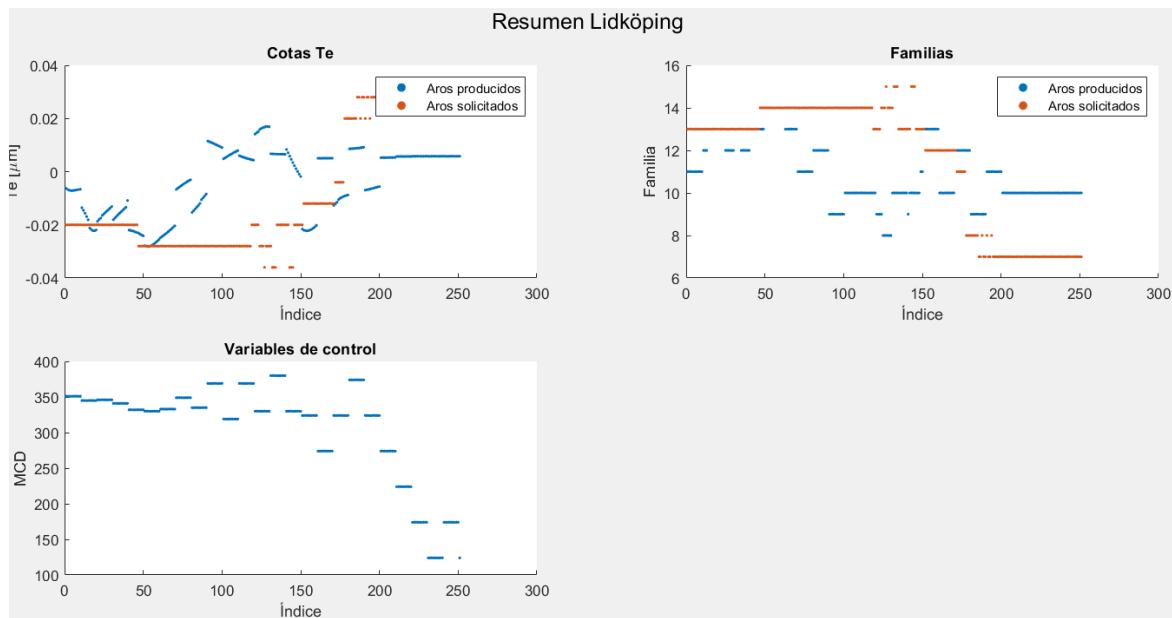
### 3 FACTORES

```

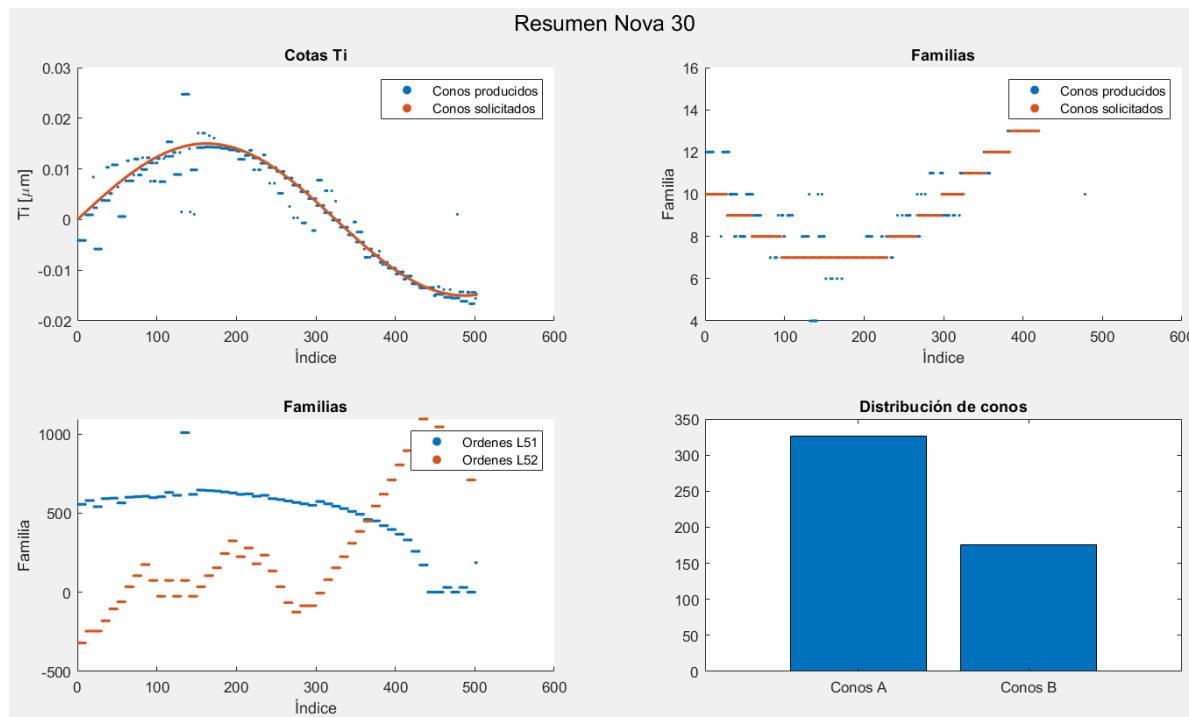
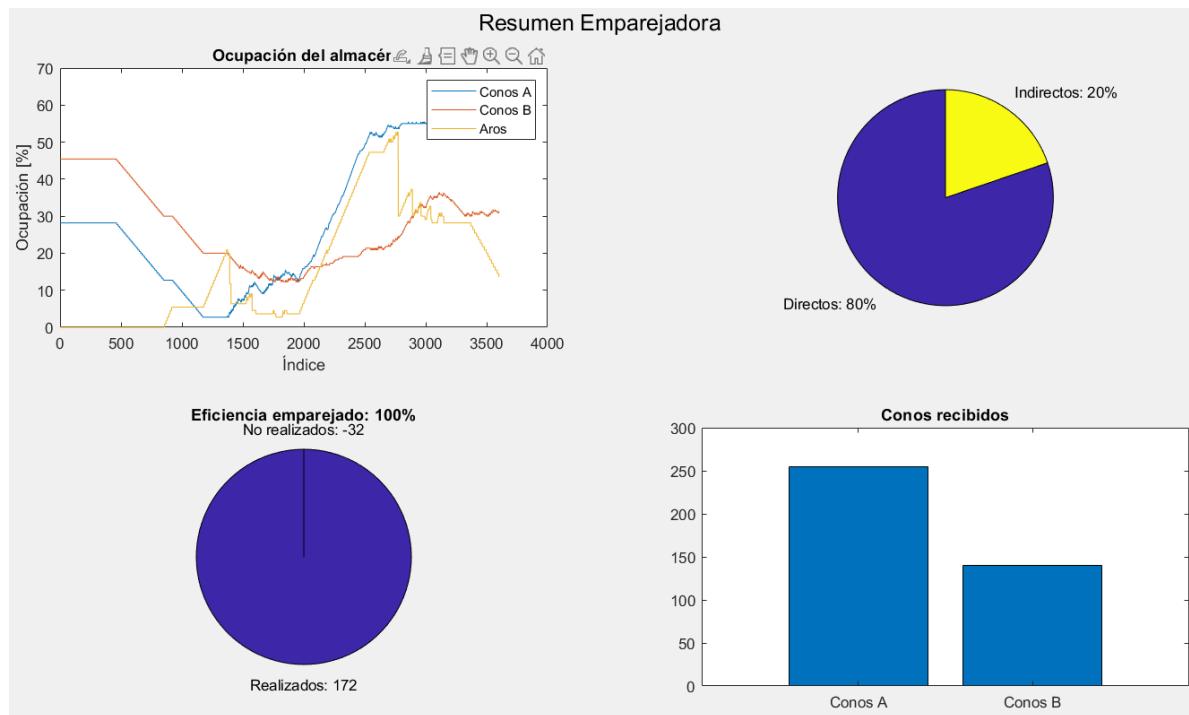
numero_factores_M06 = 3;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

```

#### **ILUSTRACIÓN 169 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL**

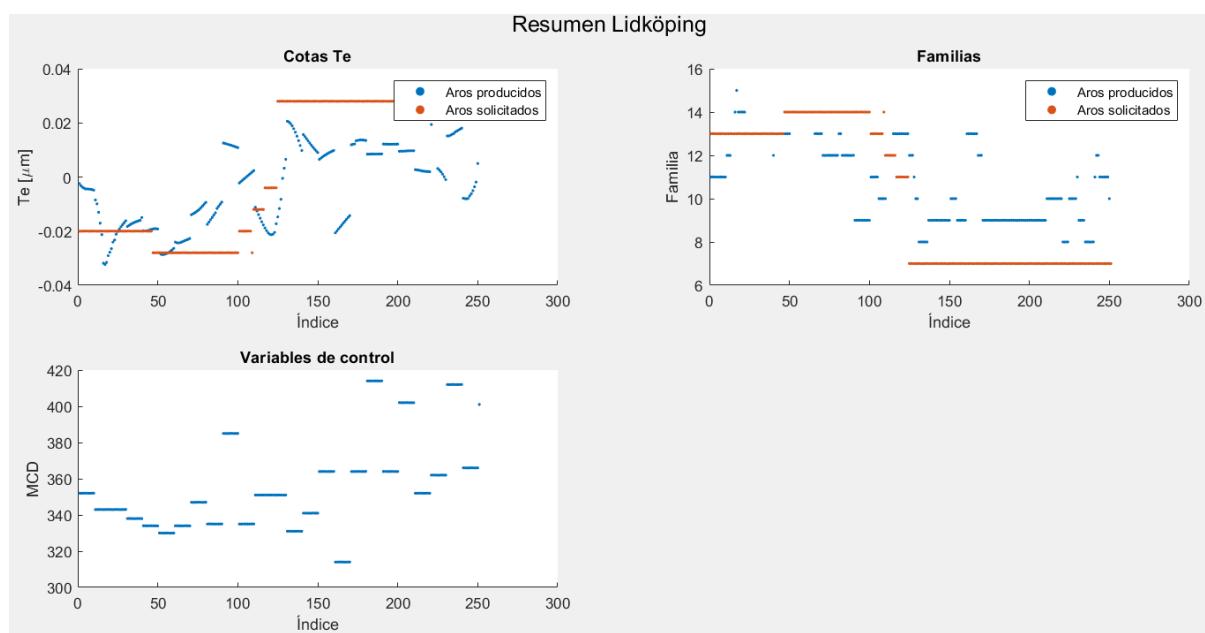


#### **ILUSTRACIÓN 170 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

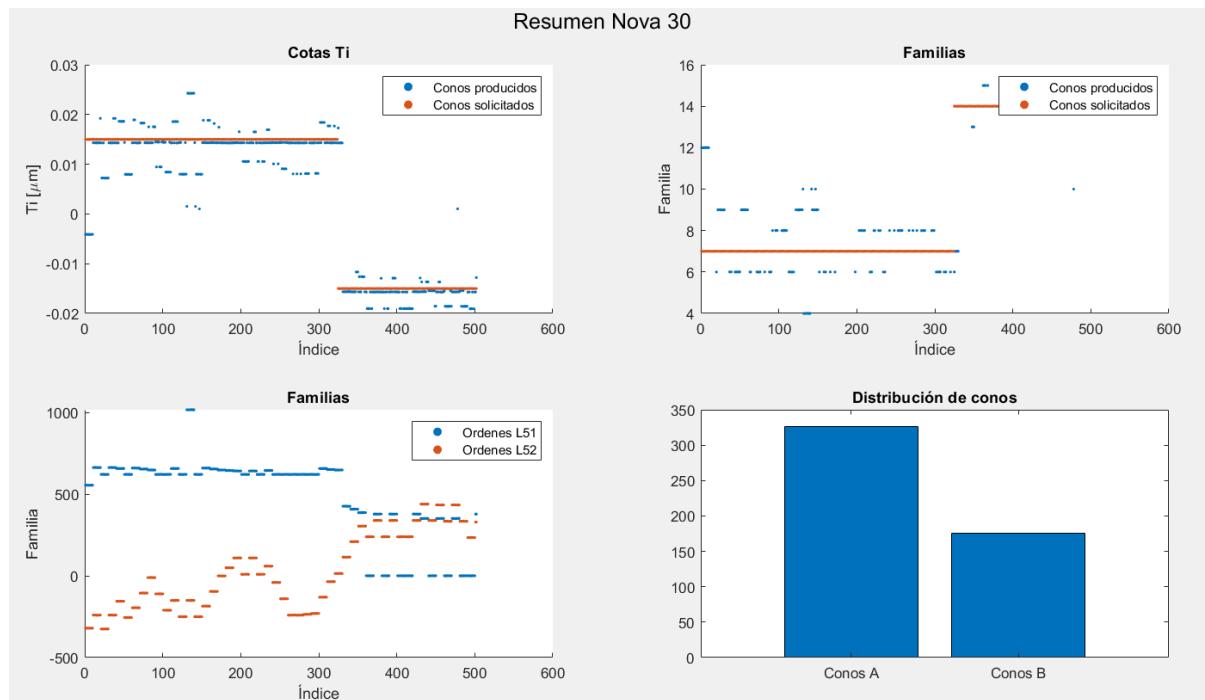
**ILUSTRACIÓN 171 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 172 RESULTADO DE LA SIMULACIÓN**

## CAMBIO EN LA DISTRIBUCIÓN DE LOS CONOS

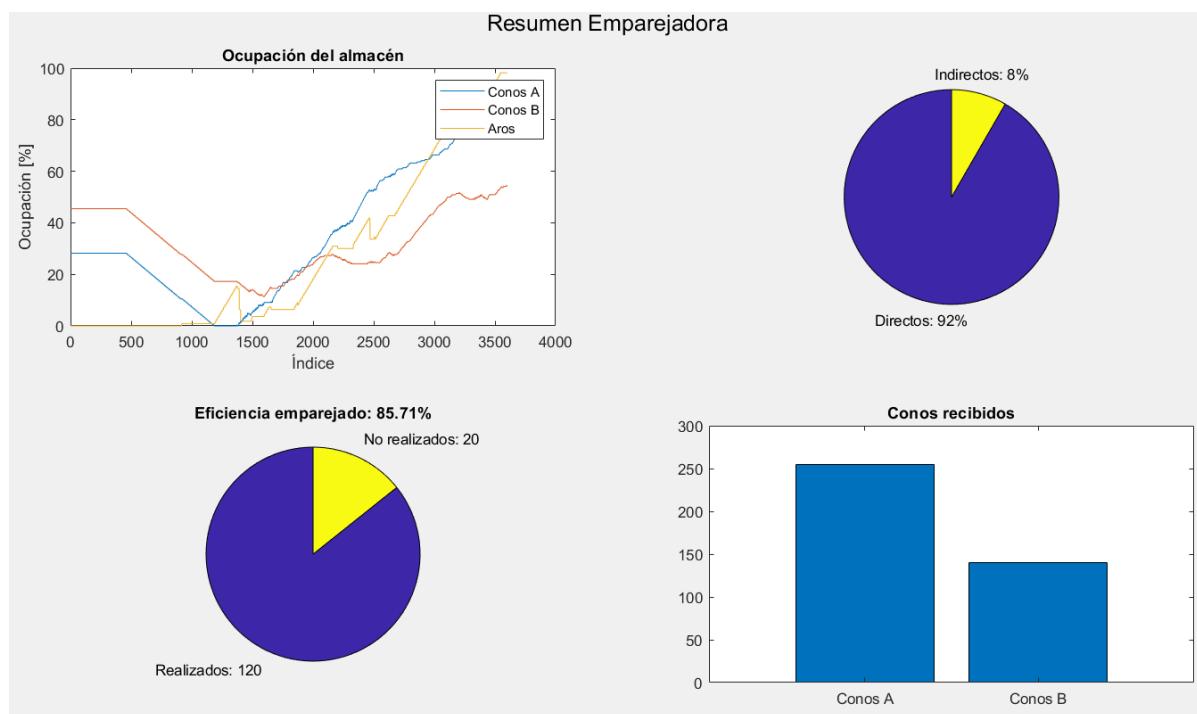
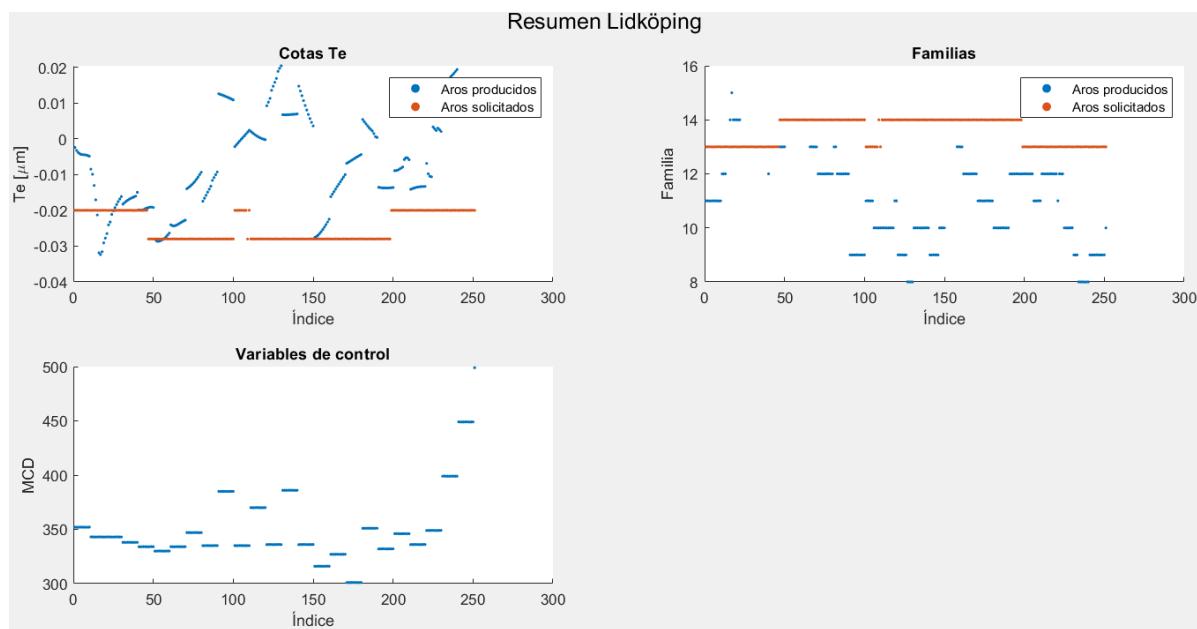
### DISTRIBUCIÓN DE ONDA CUADRADA

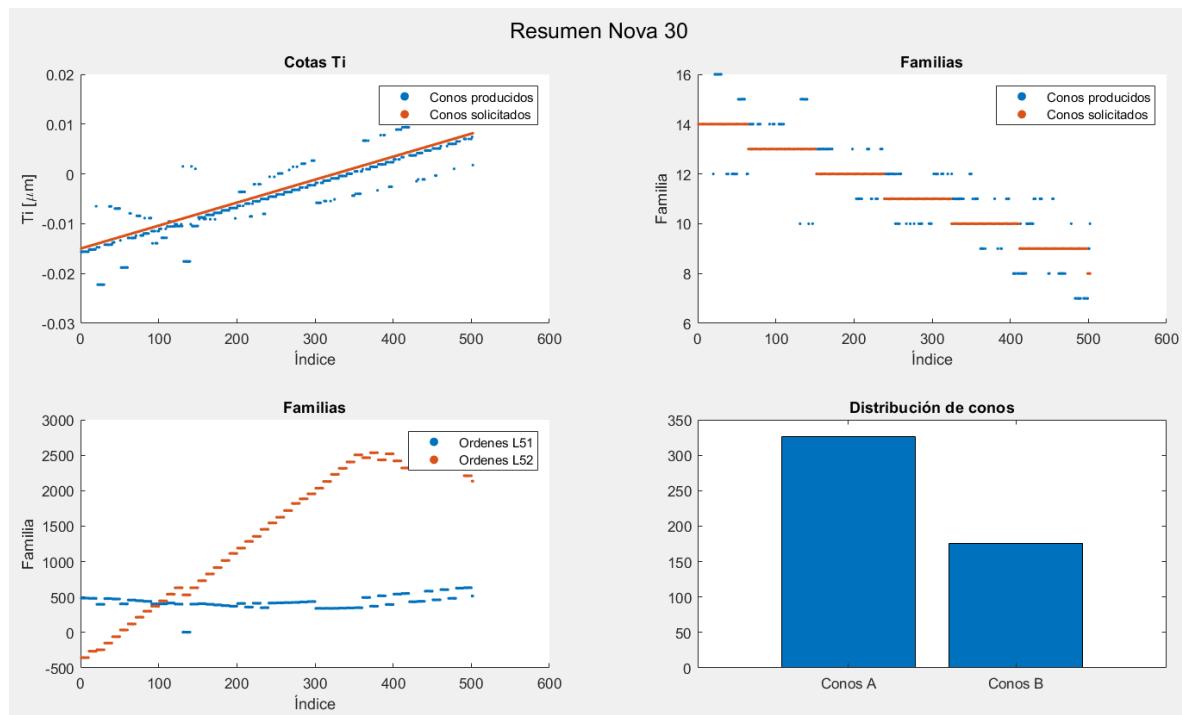


**ILUSTRACIÓN 173 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

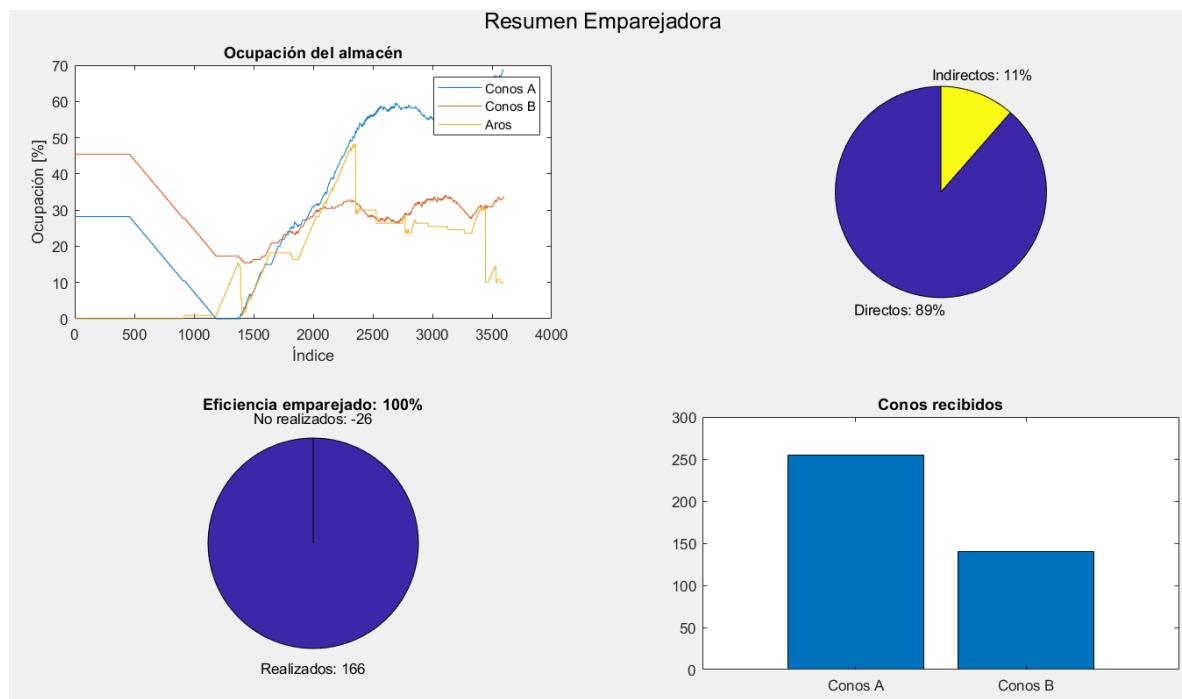


**ILUSTRACIÓN 174 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

**ILUSTRACIÓN 175 RESULTADO DE LA SIMULACIÓN****DISTRIBUCIÓN EN DIENTE DE SIERRA****ILUSTRACIÓN 176 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

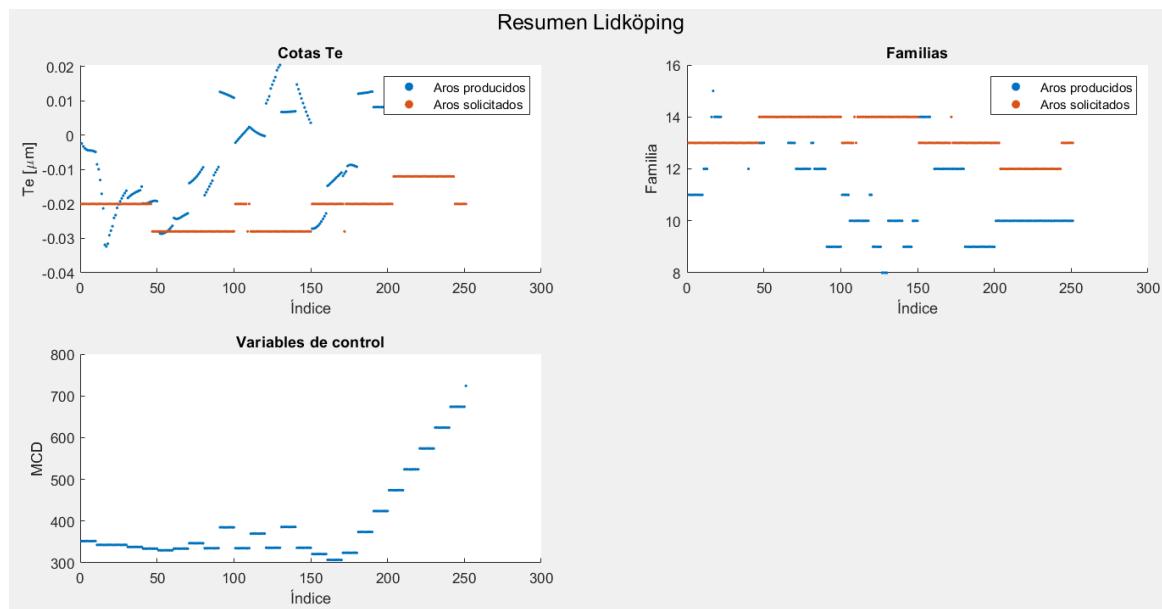


**ILUSTRACIÓN 177 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

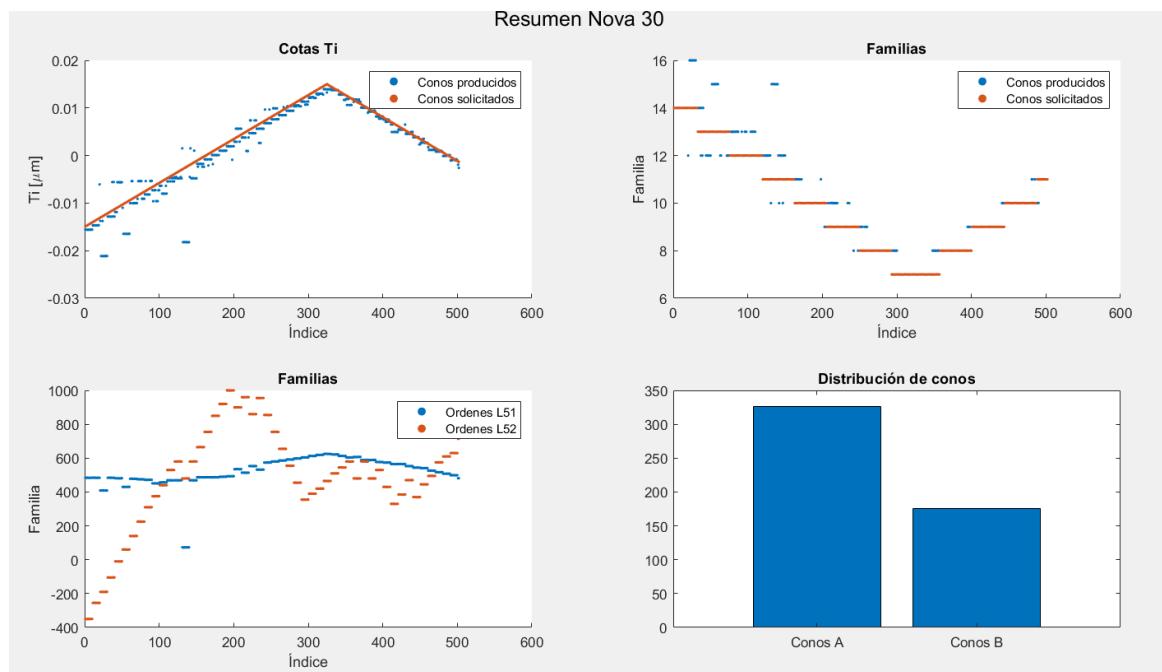


**ILUSTRACIÓN 178 RESULTADO DE LA SIMULACIÓN**

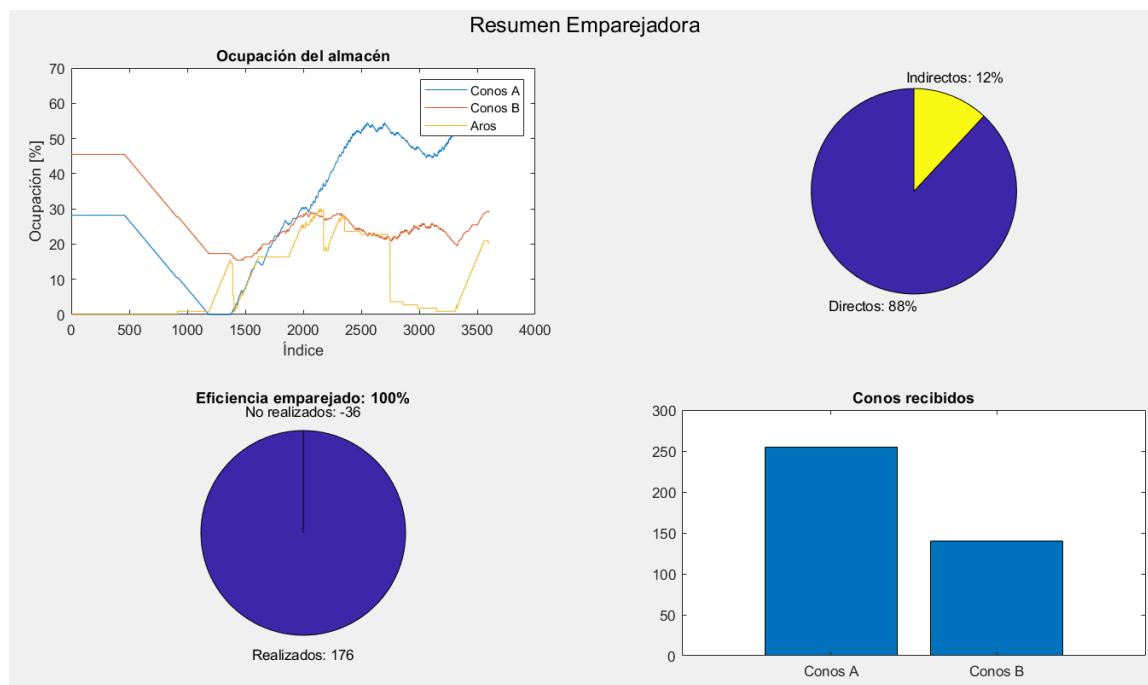
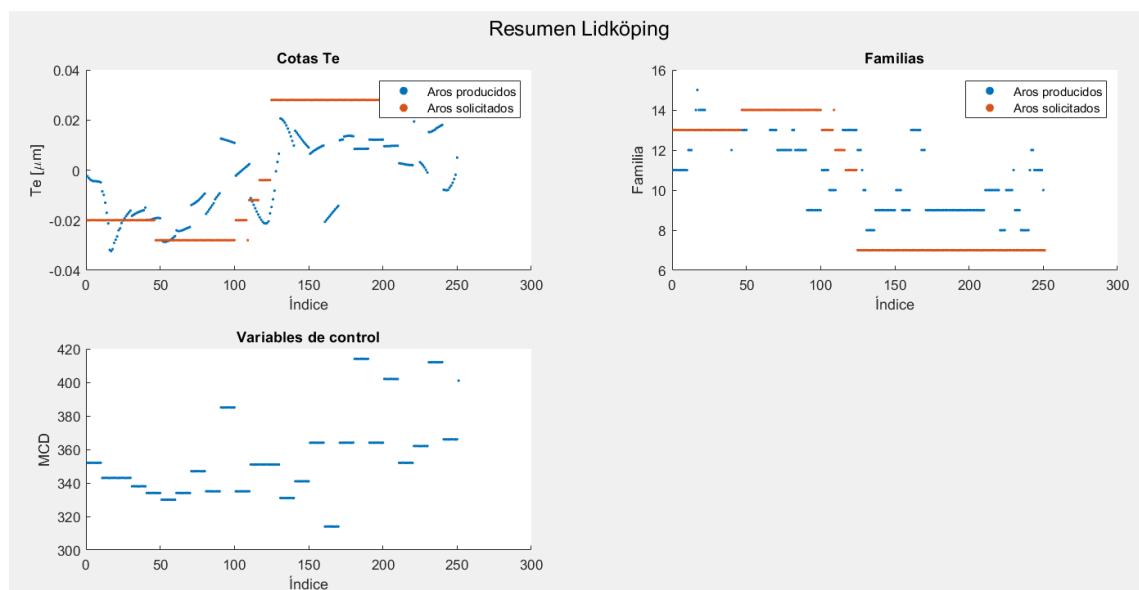
## DISTRIBUCIÓN TRIANGULAR

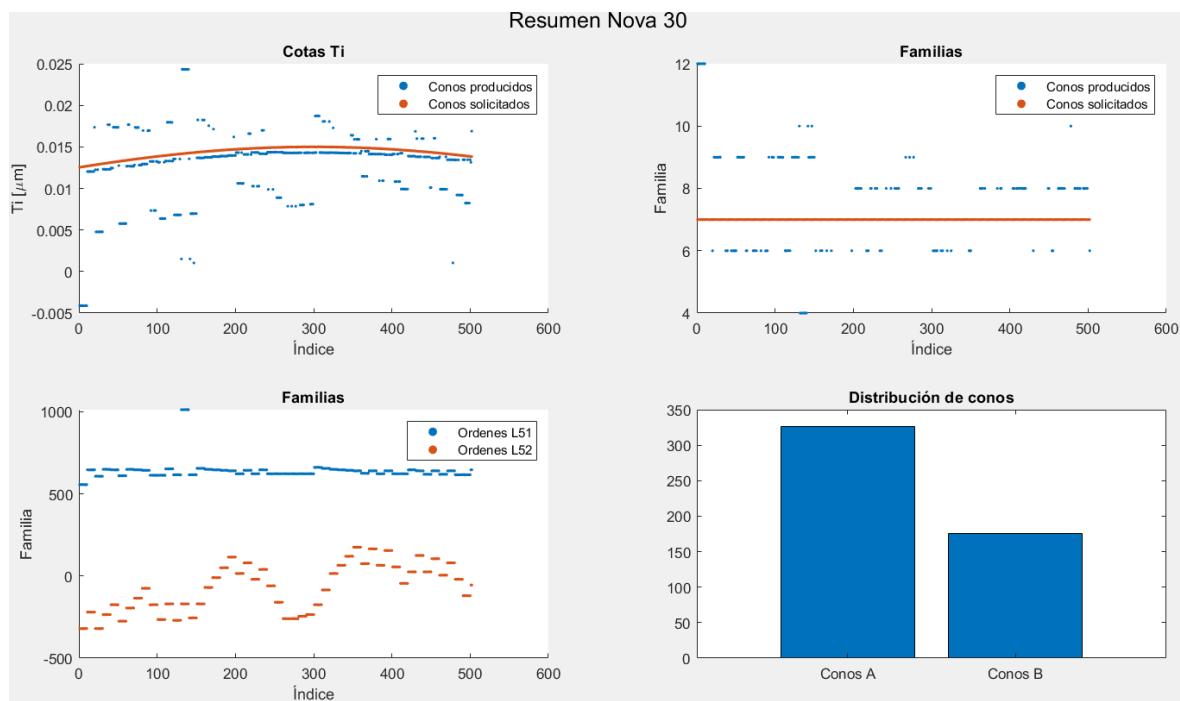
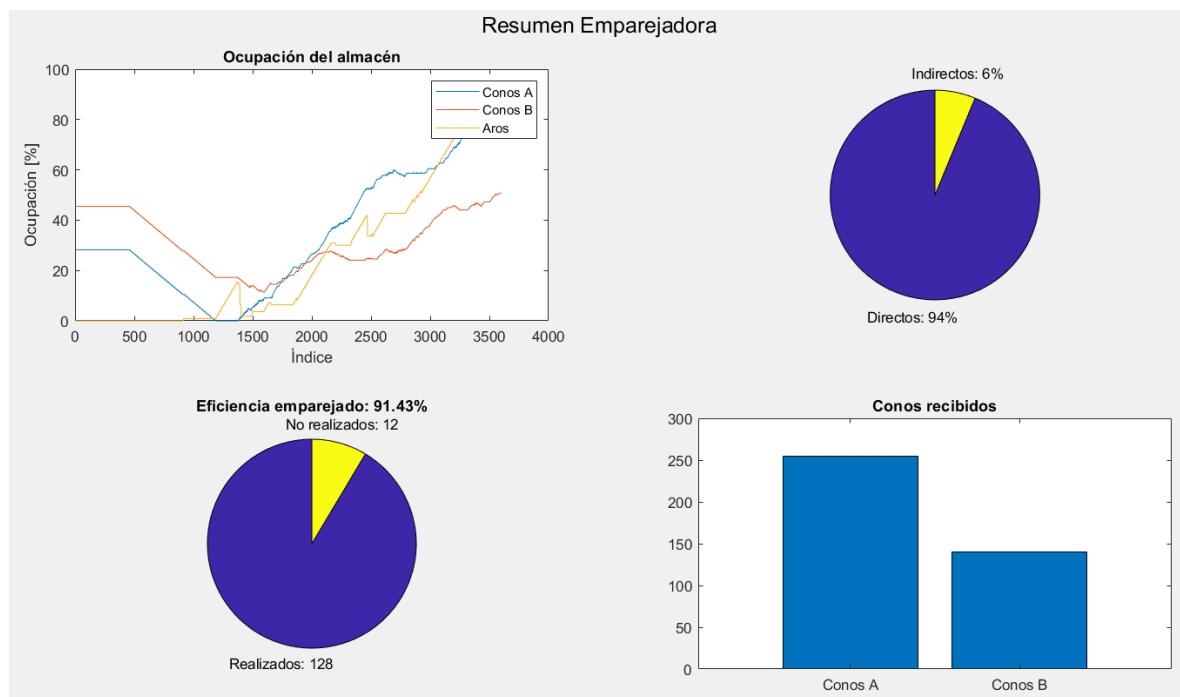


**ILUSTRACIÓN 179 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**



**ILUSTRACIÓN 180 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

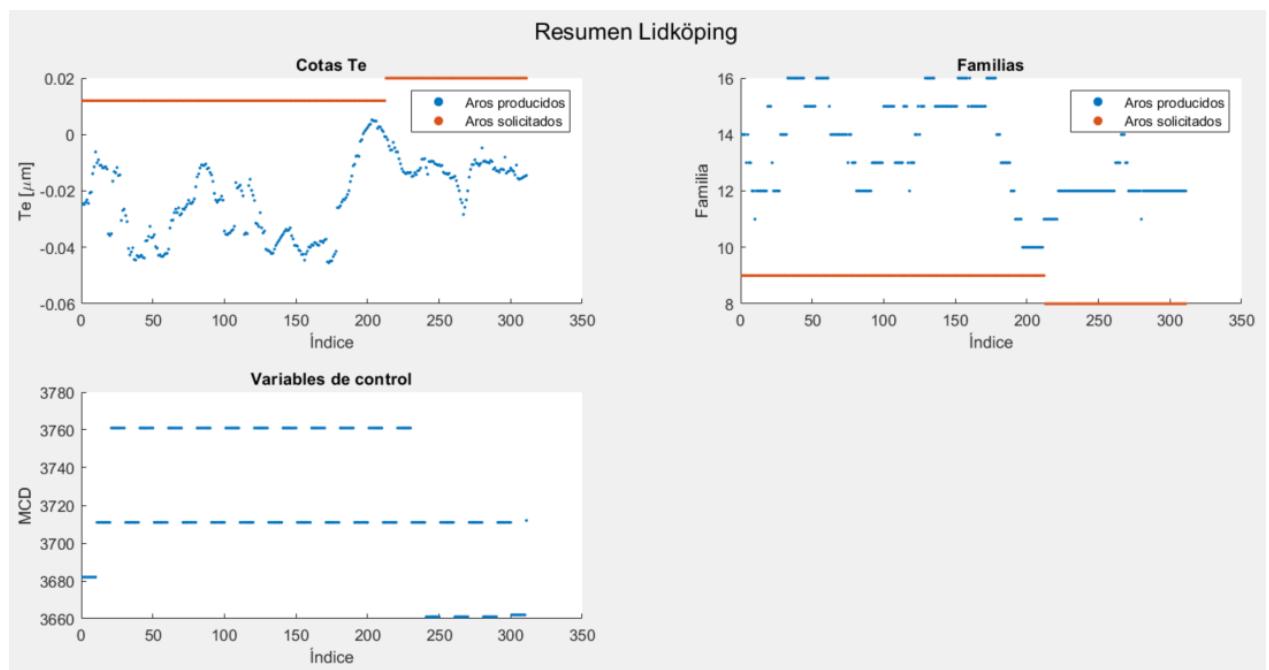
**ILUSTRACIÓN 181 RESULTADO DE LA SIMULACIÓN****DISTRIBUCIÓN GAUSSIANA****ILUSTRACIÓN 182 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

**ILUSTRACIÓN 183 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 184 RESULTADO DE LA SIMULACIÓN**

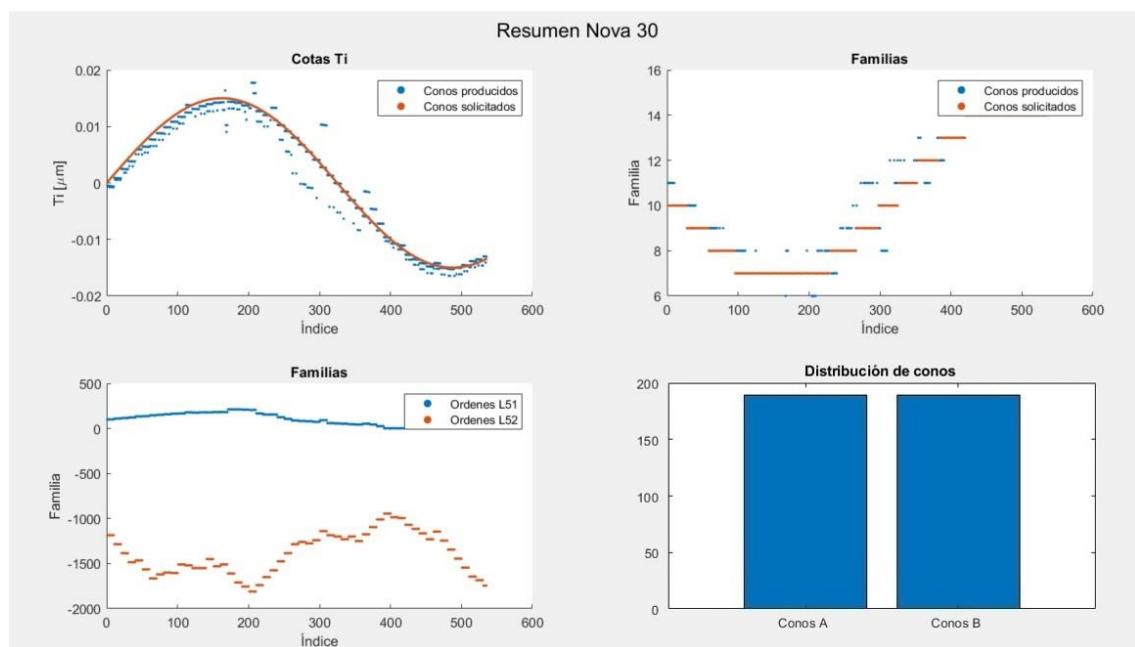
## GD CON LOS DATOS NUEVOS

### ESTRATEGIA DE EMPAREJADO

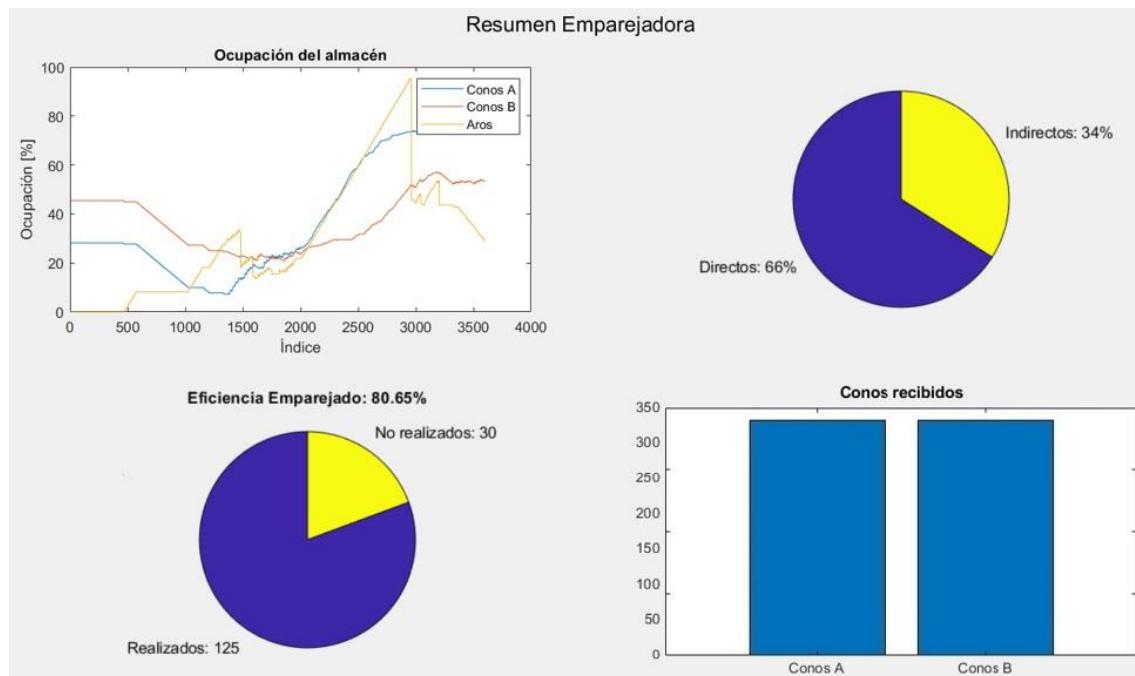
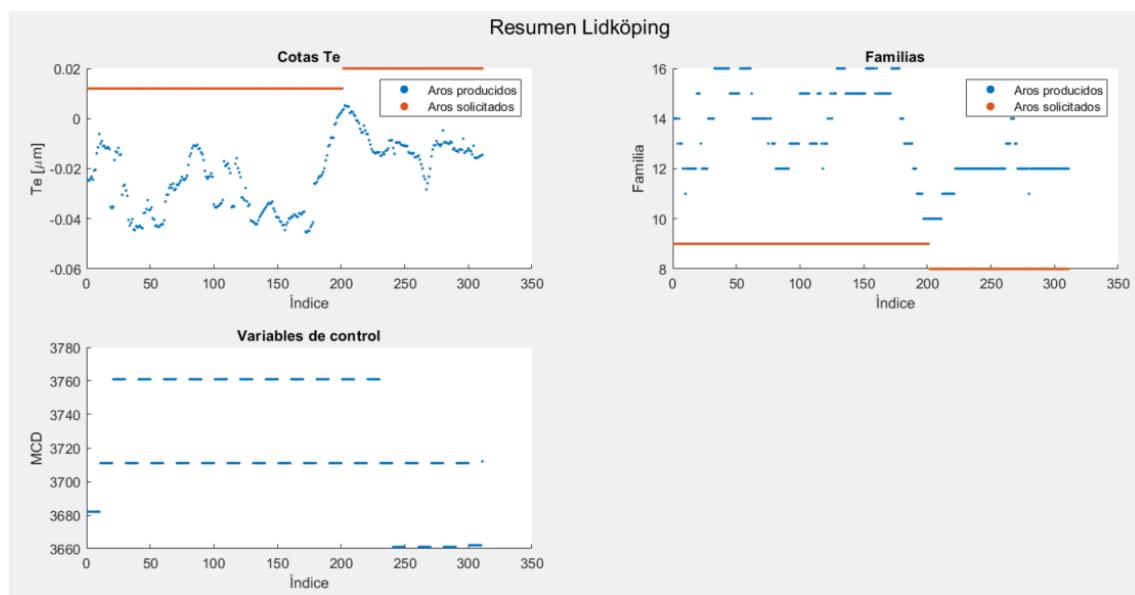
#### SOLO EMPAREJADO RECTO PERMITIDO

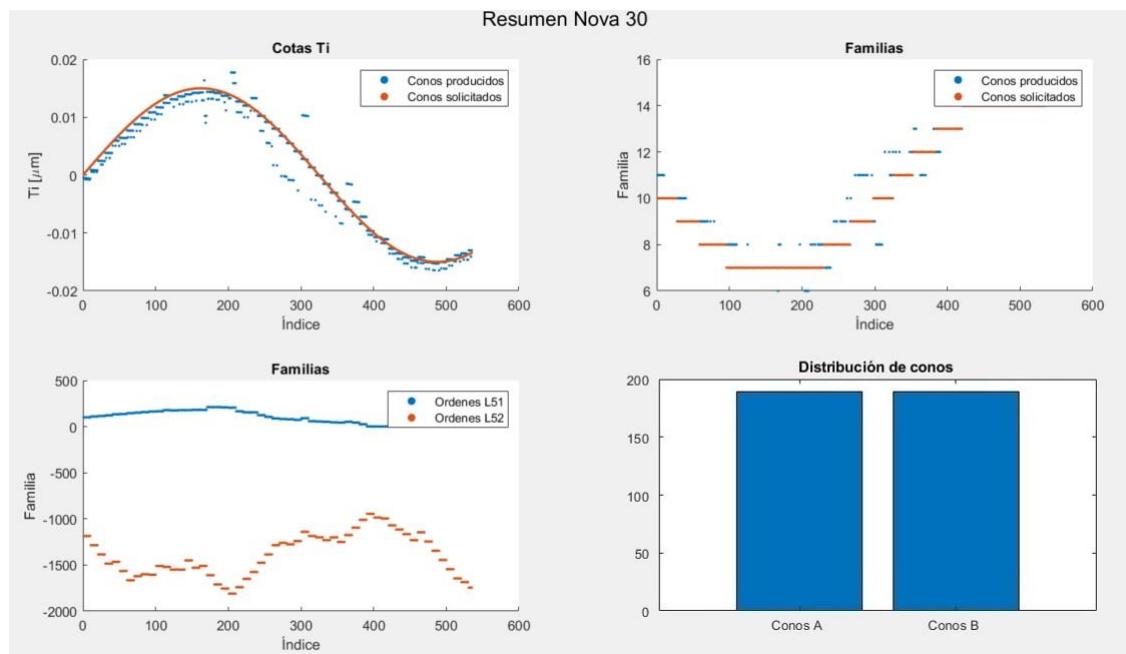
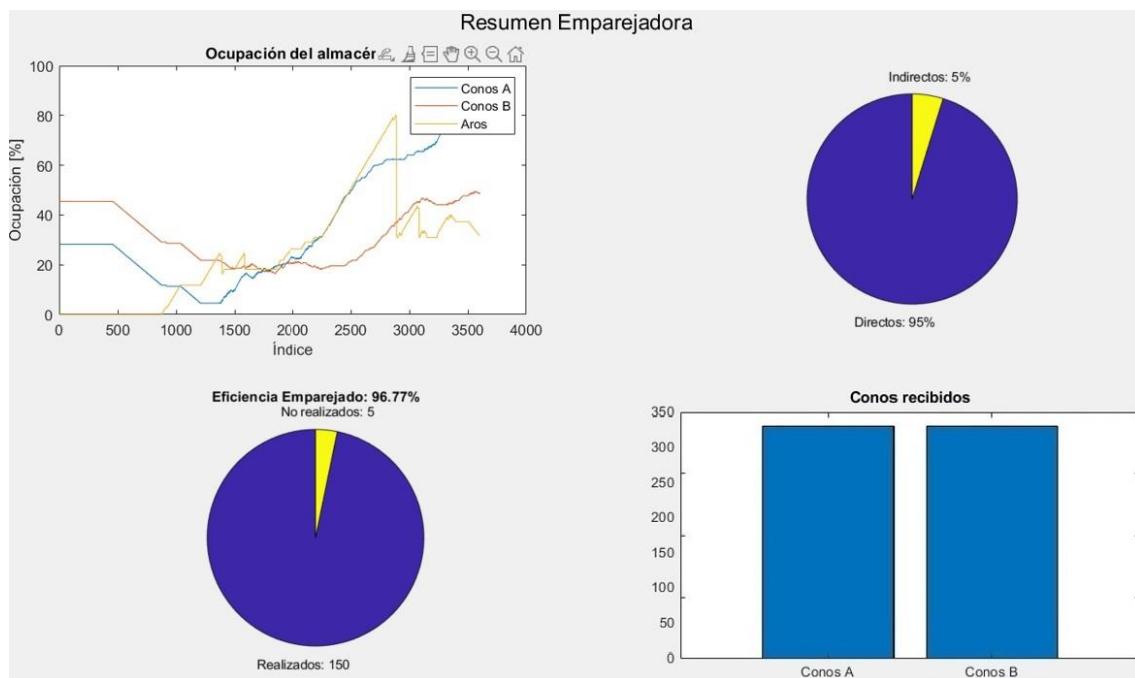


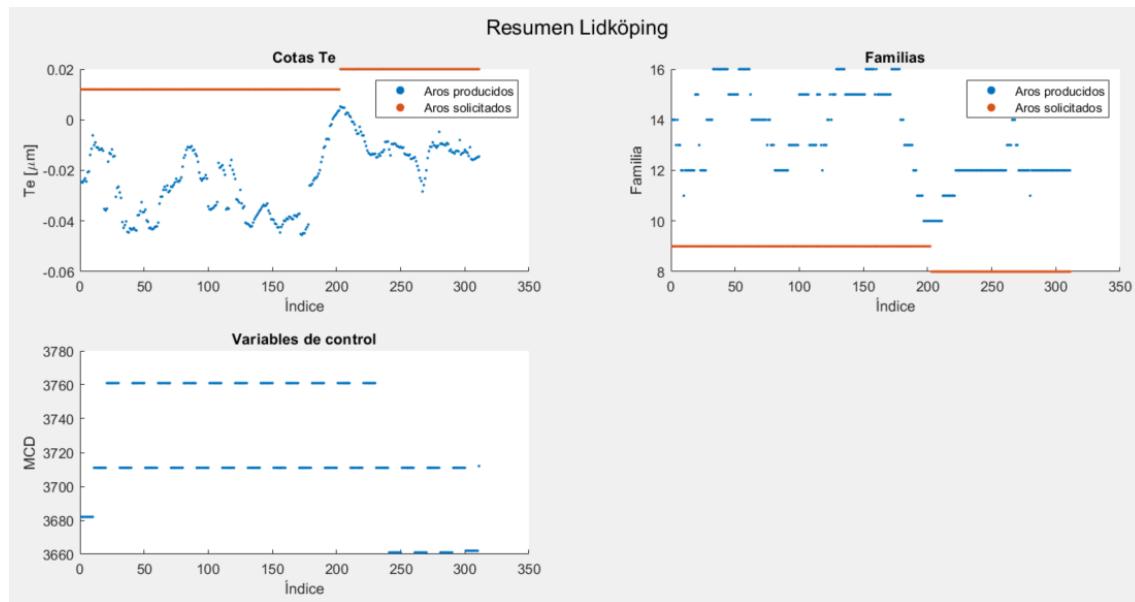
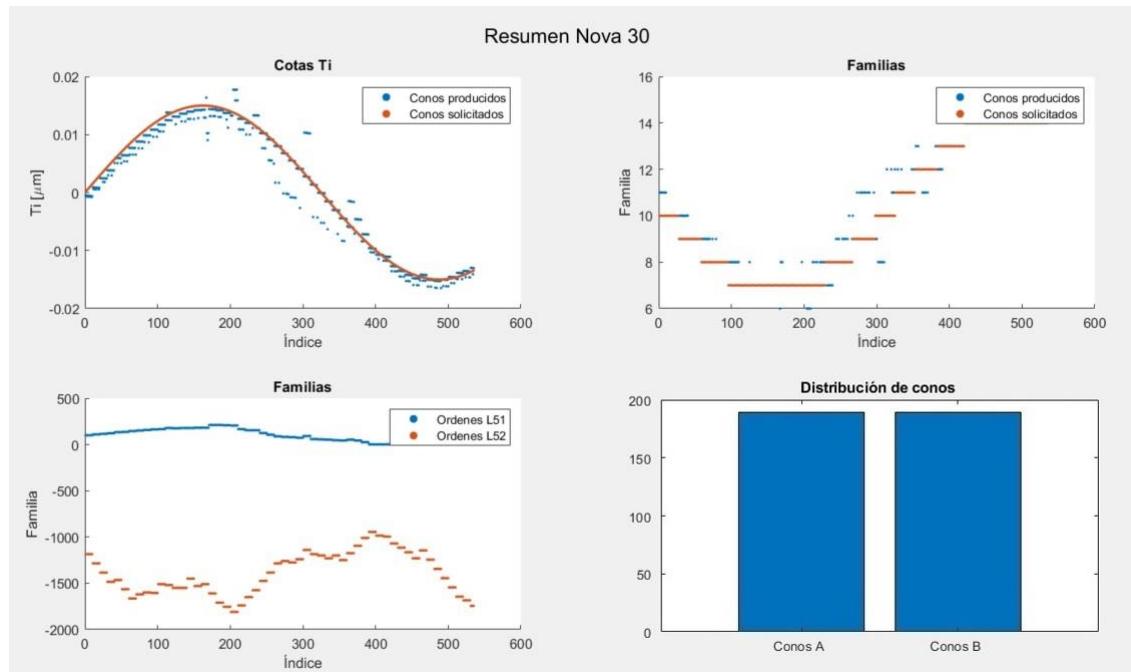
**ILUSTRACIÓN 185 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

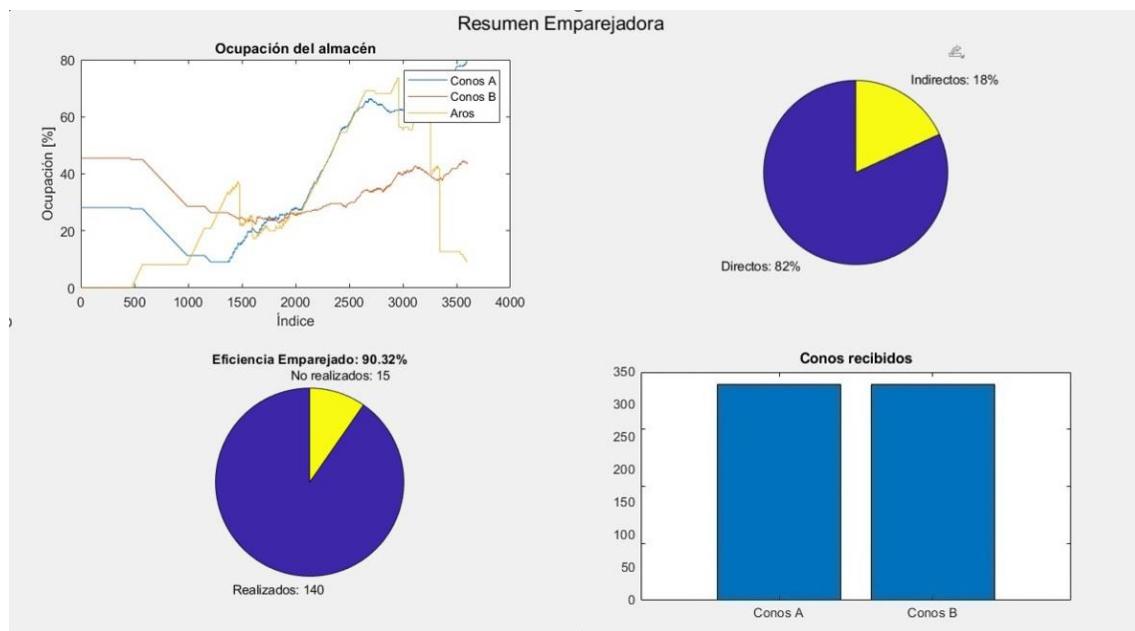
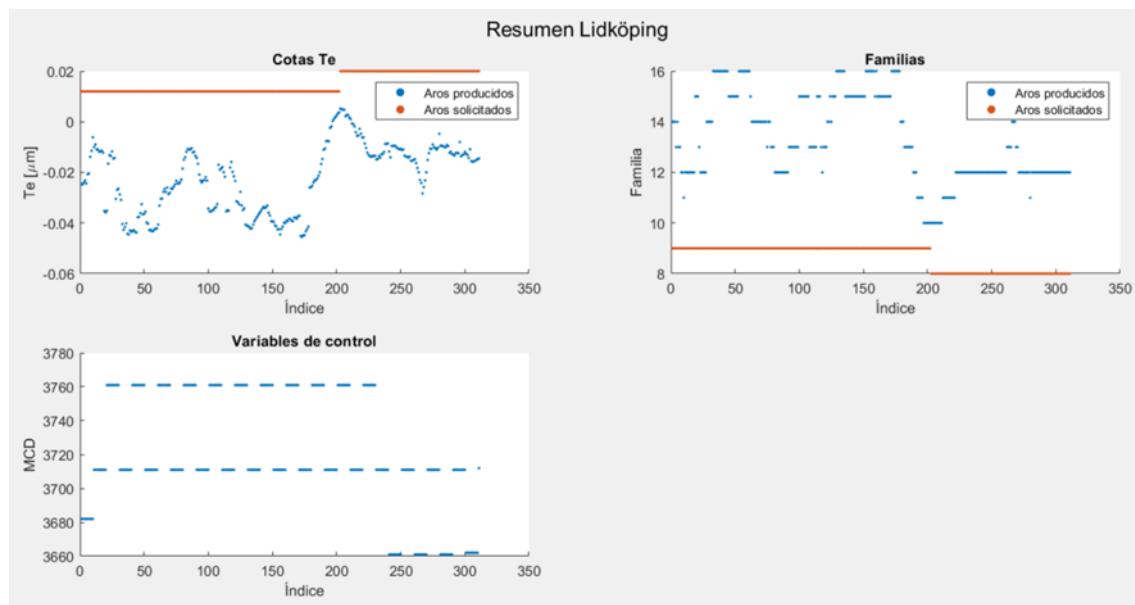


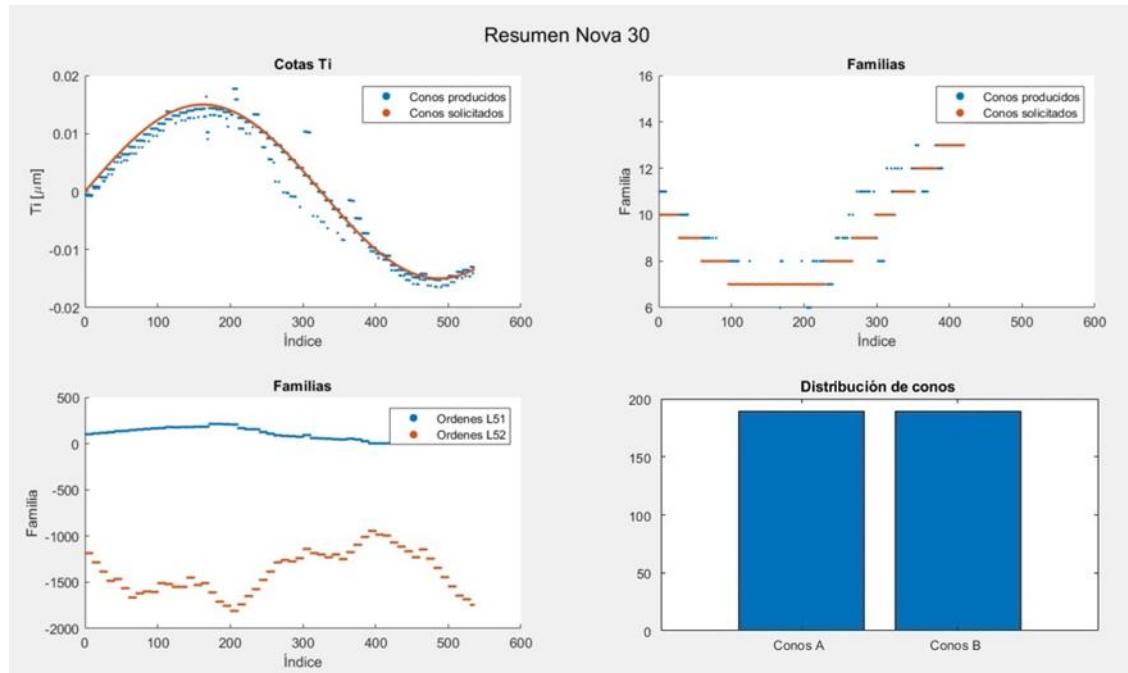
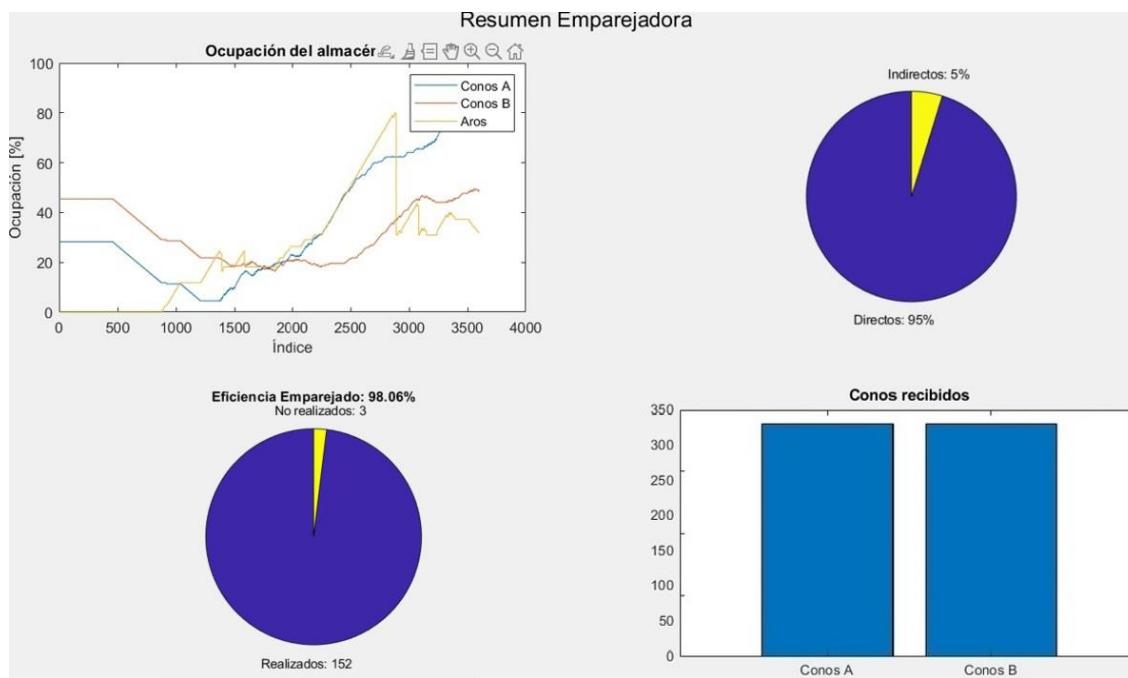
**ILUSTRACIÓN 186 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

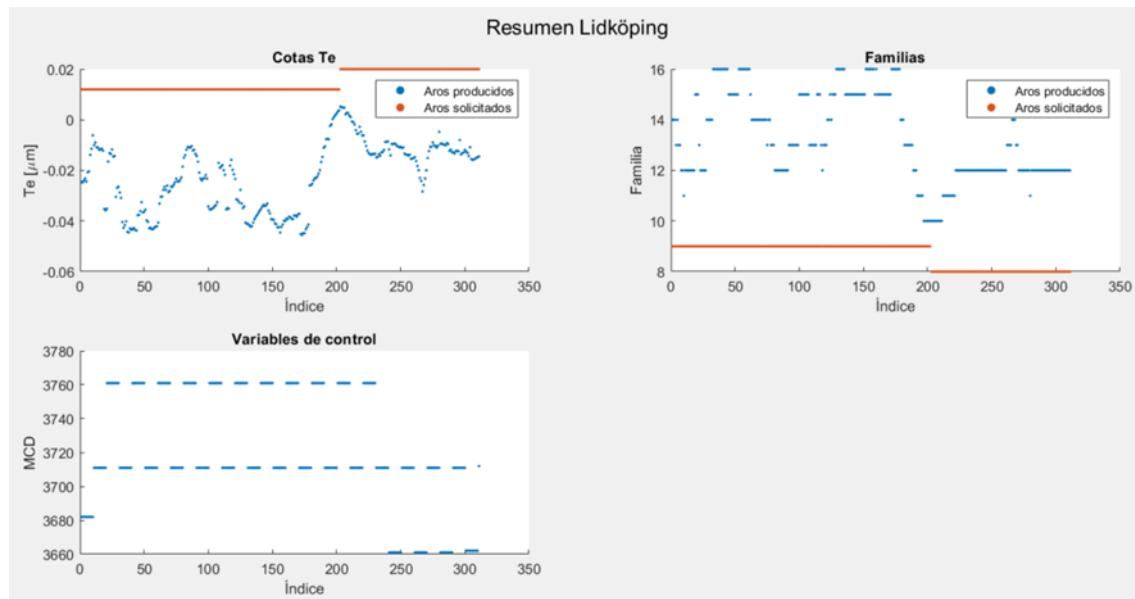
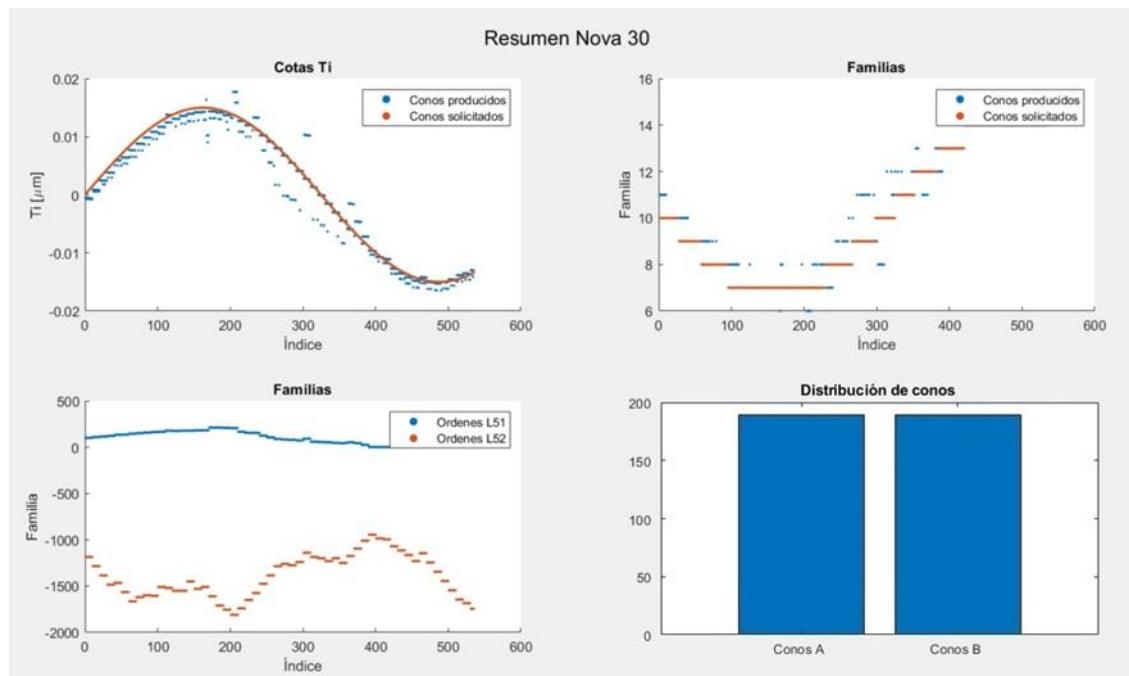
**ILUSTRACIÓN 187 RESULTADO DE LA SIMULACIÓN****EMPAREJADO RECTO Y EMPAREJADO EN L****ILUSTRACIÓN 188 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

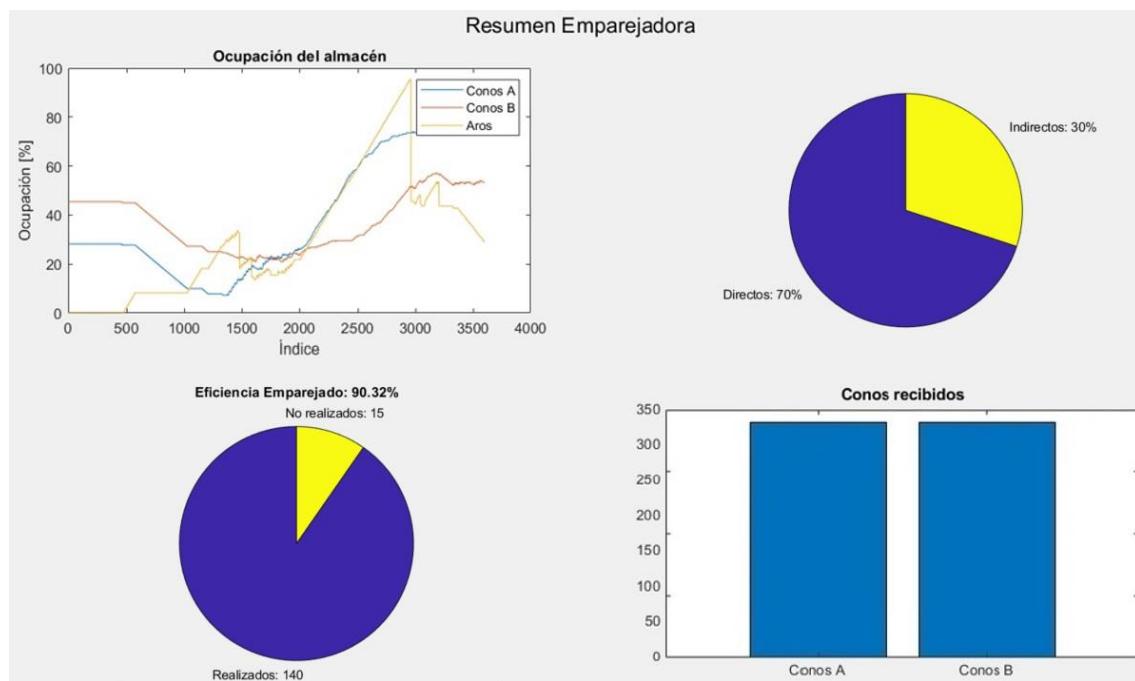
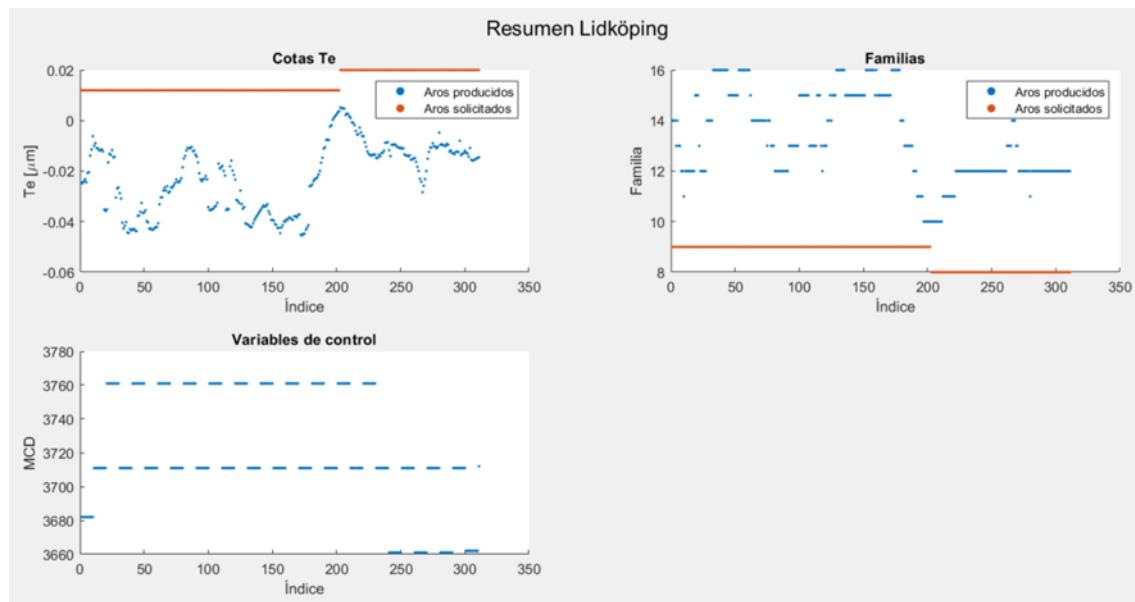
**ILUSTRACIÓN 189 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 190 RESULTADO DE LA SIMULACIÓN**

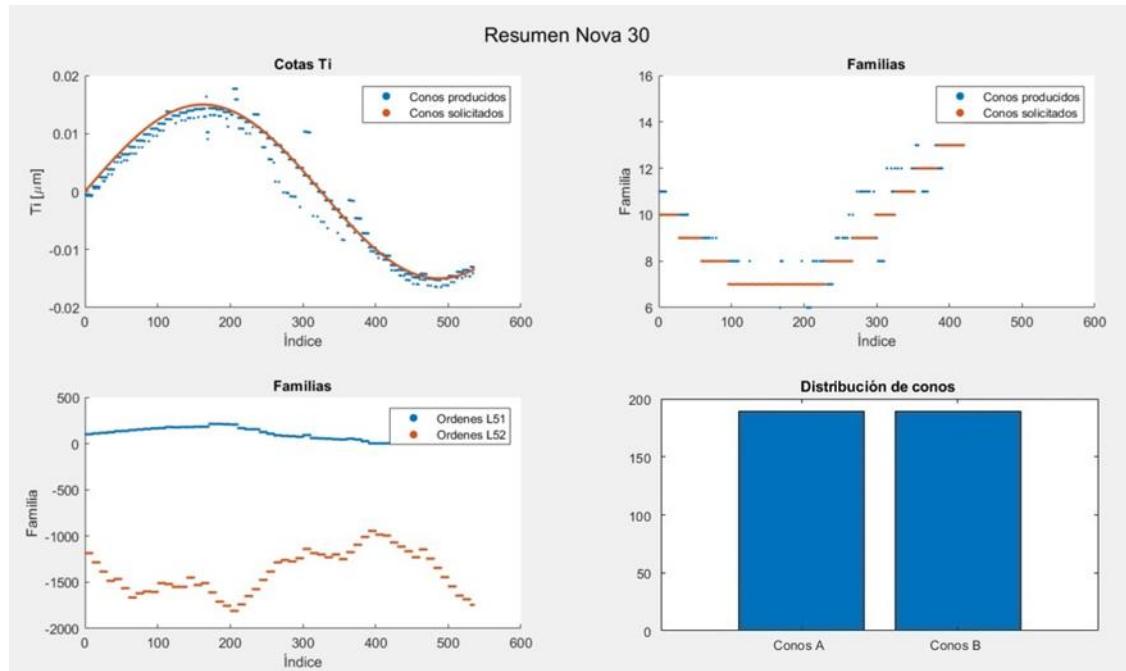
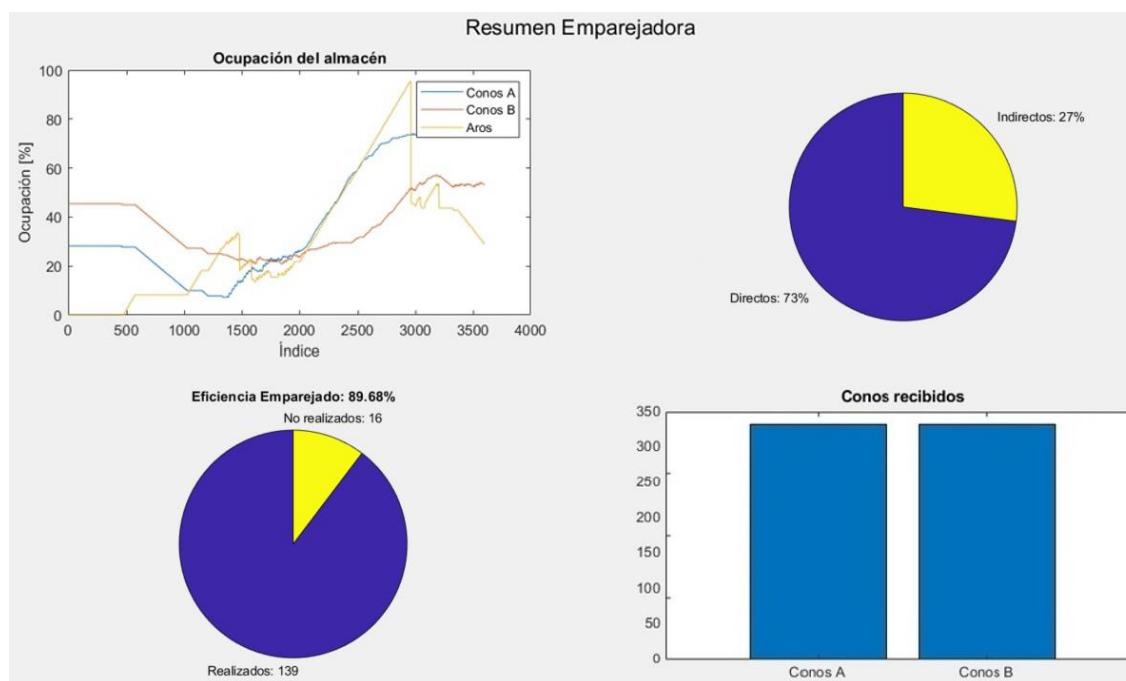
**EMPAREJADO RECTO Y EN V****ILUSTRACIÓN 191 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN****ILUSTRACIÓN 192 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

**ILUSTRACIÓN 193 RESULTADO DE LA SIMULACIÓN****EMPAРЕJADO EN L Y EN V****ILUSTRACIÓN 194 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

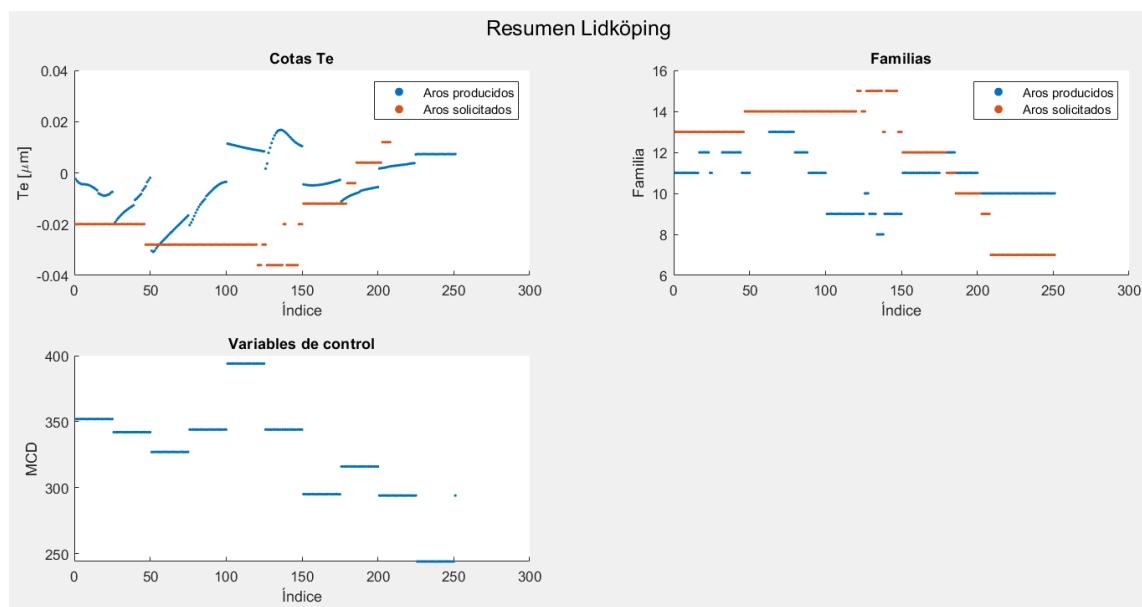
**ILUSTRACIÓN 195 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 196 RESULTADO DE LA SIMULACIÓN**

**SOLO EMPAREJADO EN L****ILUSTRACIÓN 197 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN****ILUSTRACIÓN 198 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

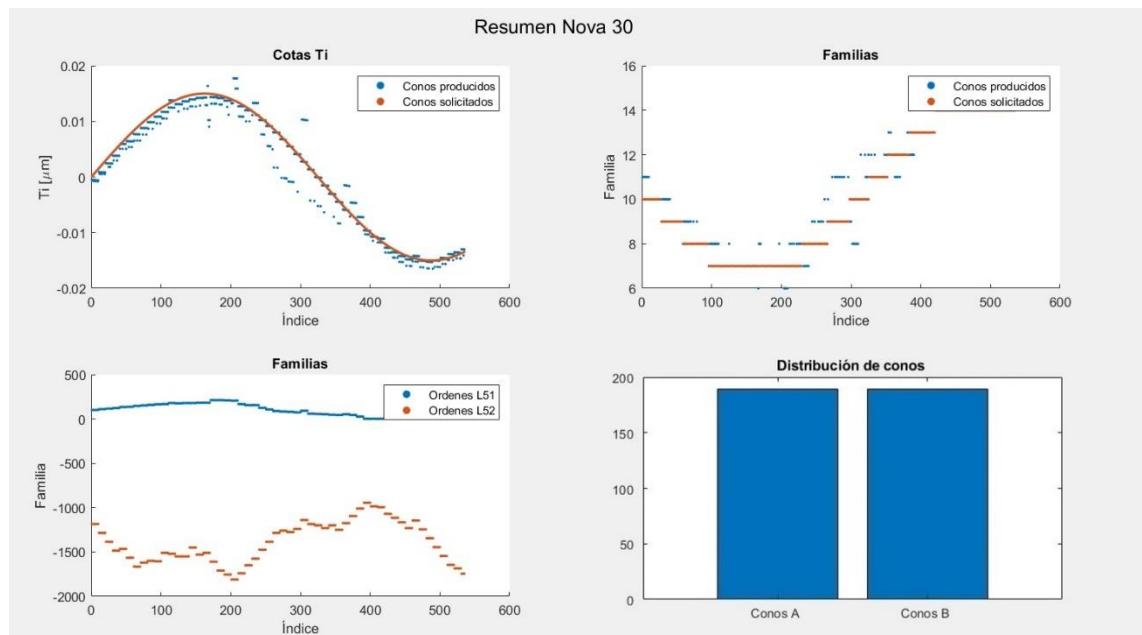
**ILUSTRACIÓN 199 RESULTADO DE LA SIMULACIÓN****SOLO EMPAREJADO EN V****ILUSTRACIÓN 200 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

**ILUSTRACIÓN 201 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL****ILUSTRACIÓN 202 RESULTADO DE LA SIMULACIÓN**

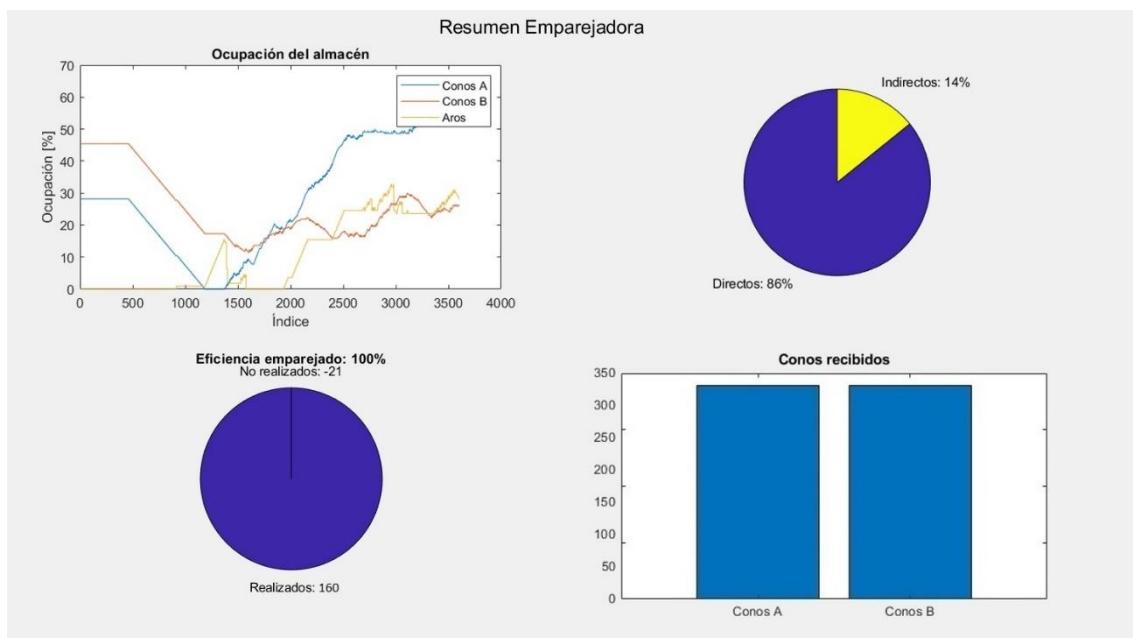
## CAMBIO EN LA FRECUENCIA DE AJUSTE DE LA RECTIFICADORA DE AROS A 25



**ILUSTRACIÓN 203 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**



**ILUSTRACIÓN 204 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

**ILUSTRACIÓN 205 RESULTADO DE LA SIMULACIÓN****CAMBIO EN EL NUMERO DE FACTORES****7 FACTORES**

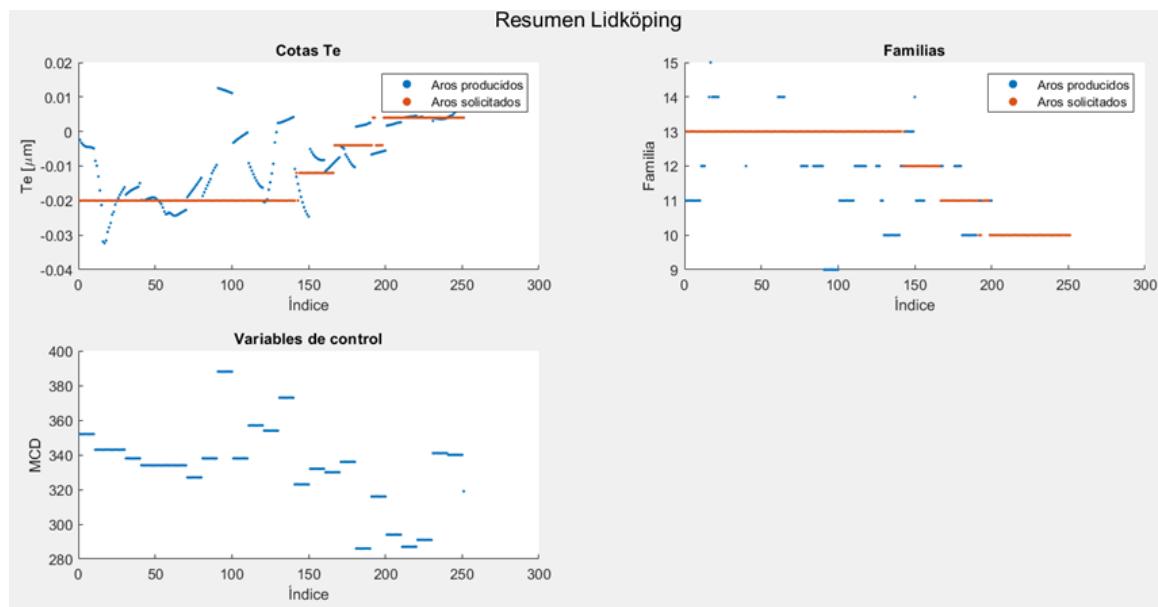
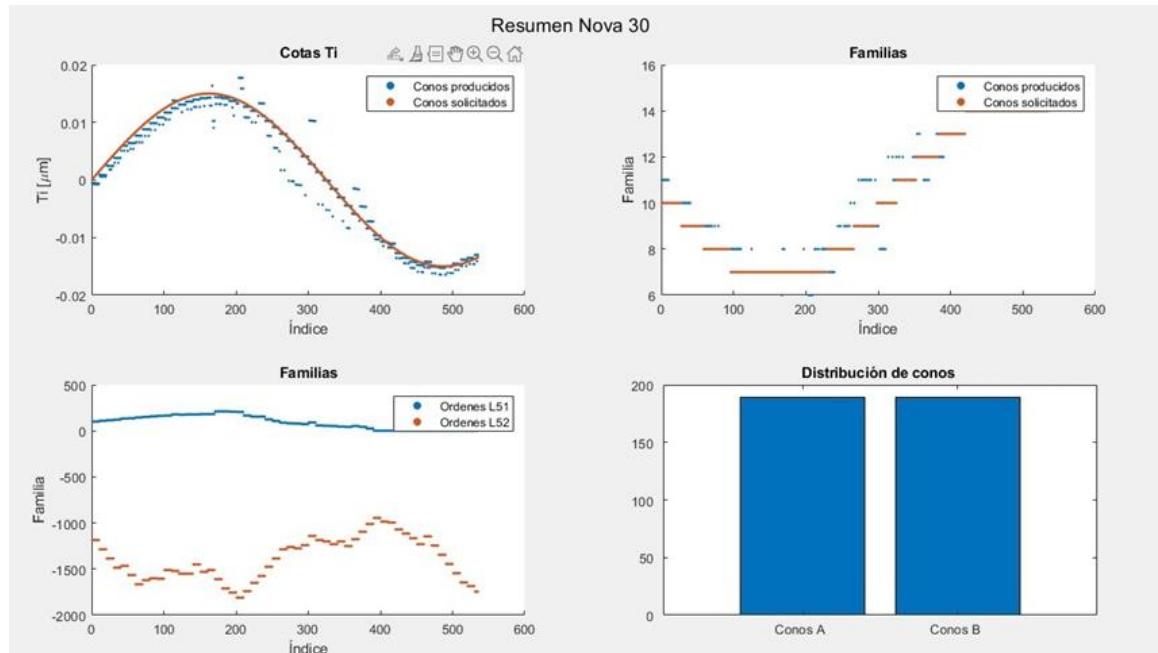
```

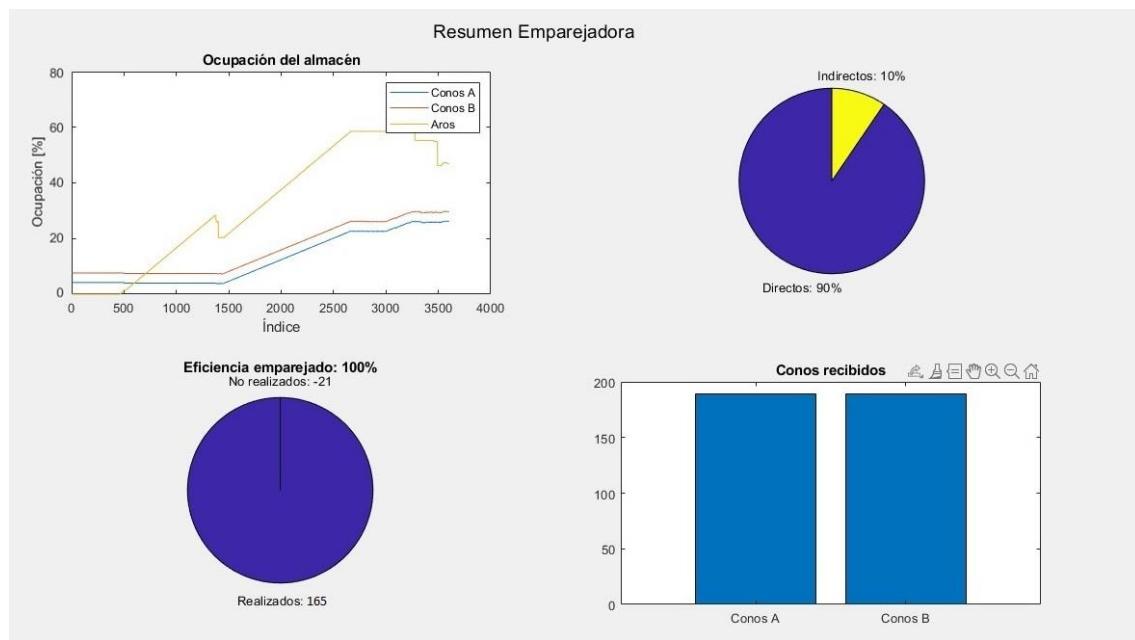
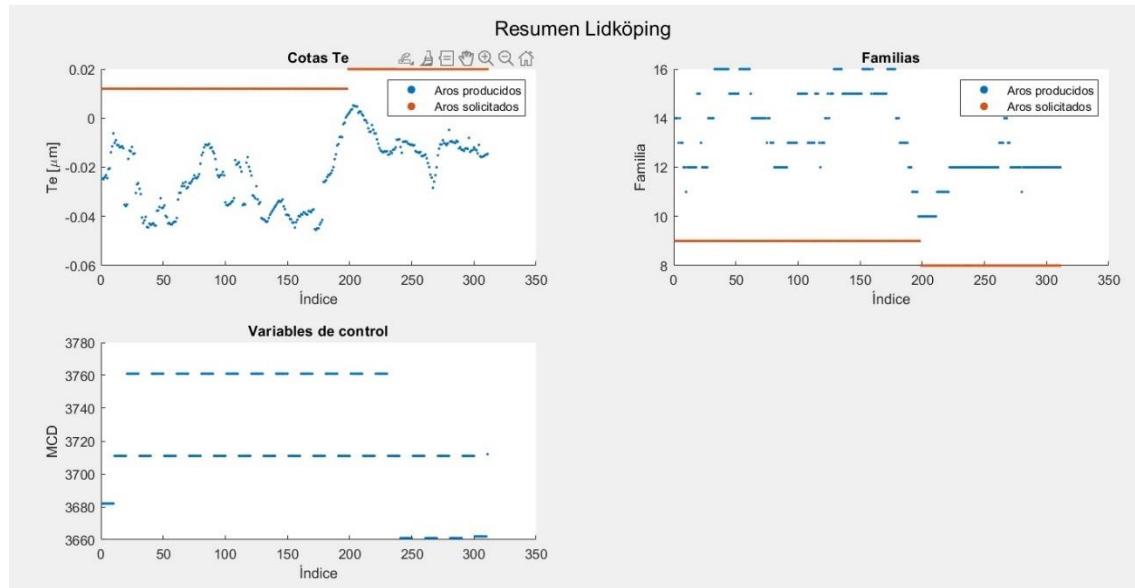
numero_factores_M06 = 7;
num_fact_conosA = 5;
num_fact_conosB = 5;
intervalo_ajuste_M06 = 10;
int_ajuste_M11 = 10;
distribuciones.usar_conos = 1;
distribuciones.distr_ini_conoA = zeros(1,20);
distribuciones.distr_ini_conoB = zeros(1,20);
distribuciones.usar_aros = 0;
distribuciones.distr_ini_aros = zeros(1,20);
patron_conos.A = 15;
patron_conos.T = 650;
estrategia_emparejado.recto = 1;
estrategia_emparejado.L = 1;
estrategia_emparejado.V = 1;

grabar_videos = 0;
mostrar_figuras = 1;

```

**ILUSTRACIÓN 206 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL**

**ILUSTRACIÓN 207 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN****ILUSTRACIÓN 208 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

**ILUSTRACIÓN 209 RESULTADO DE LA SIMULACIÓN****4 FACTORES****ILUSTRACIÓN 210 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

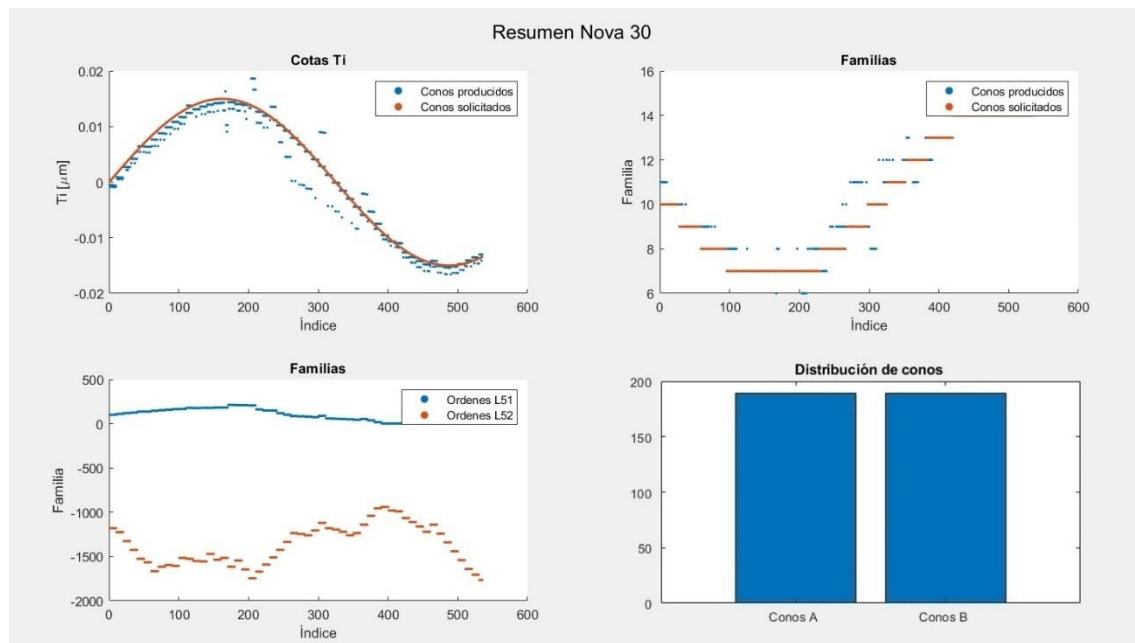


ILUSTRACIÓN 211 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL

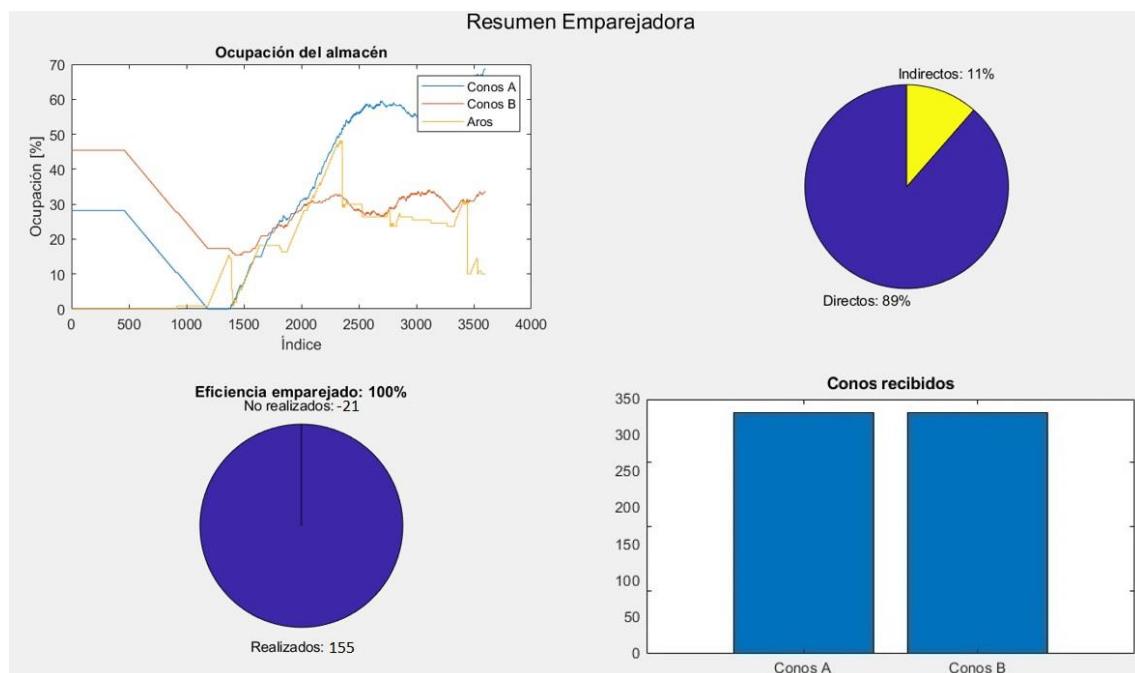
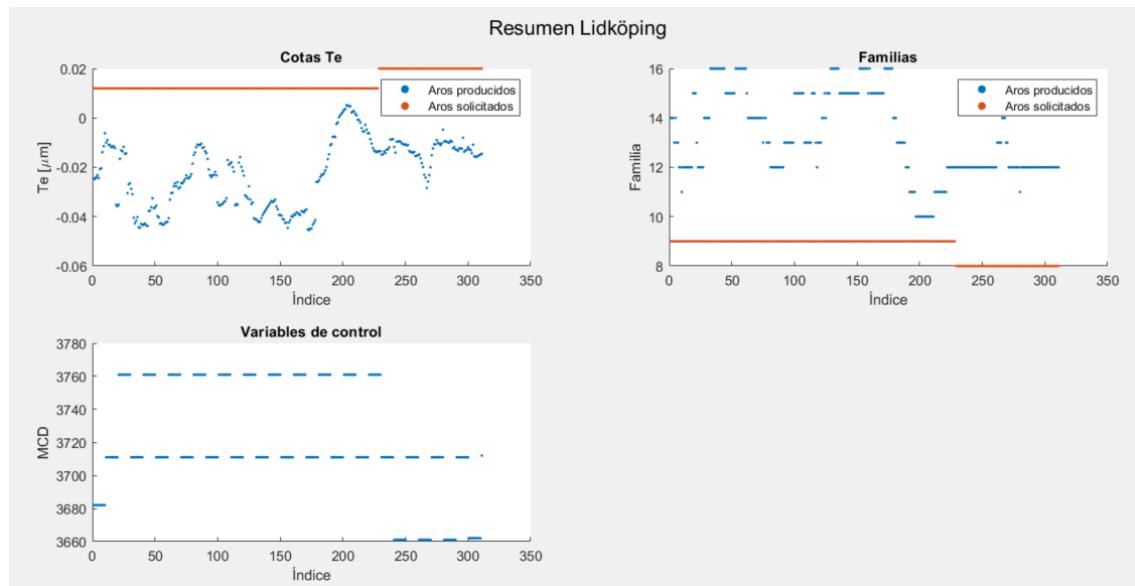
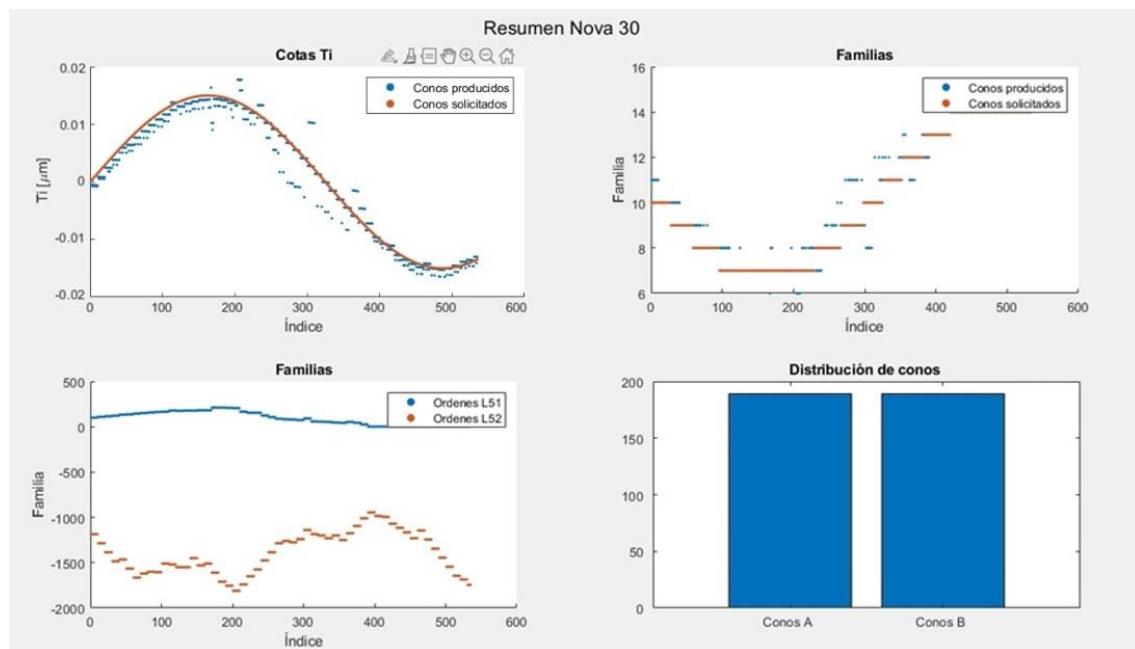


ILUSTRACIÓN 212 RESULTADO DE LA SIMULACIÓN

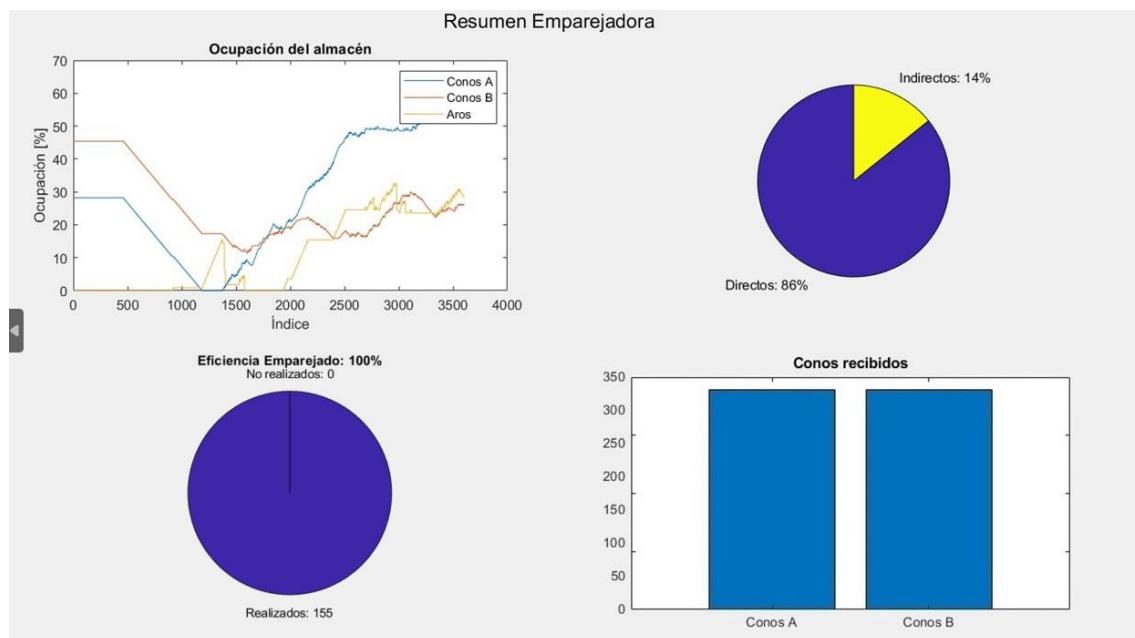
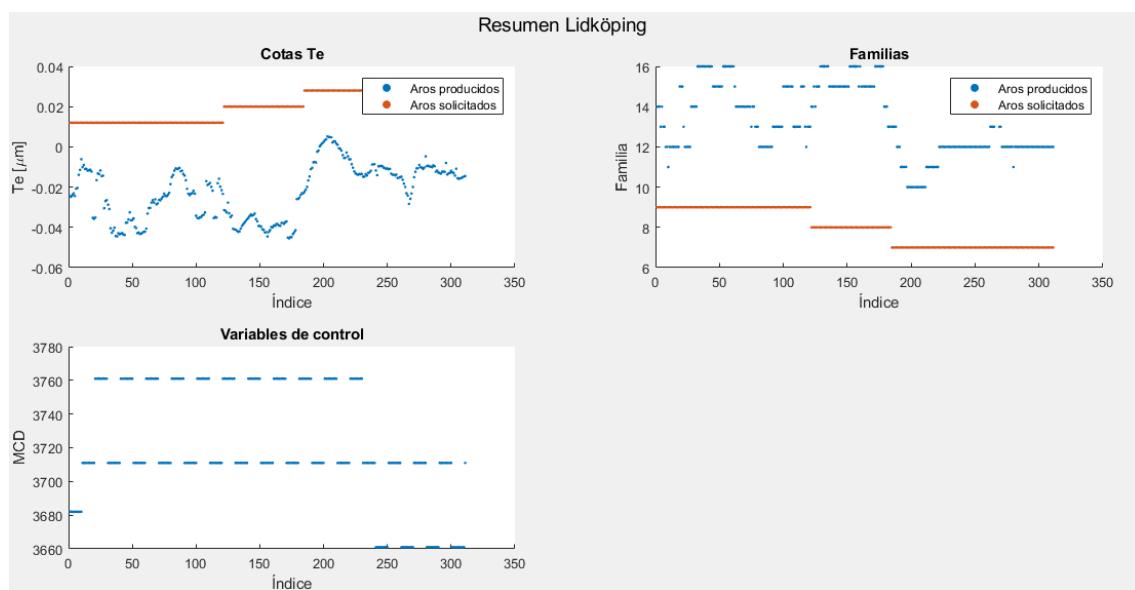
### 3 FACTORES

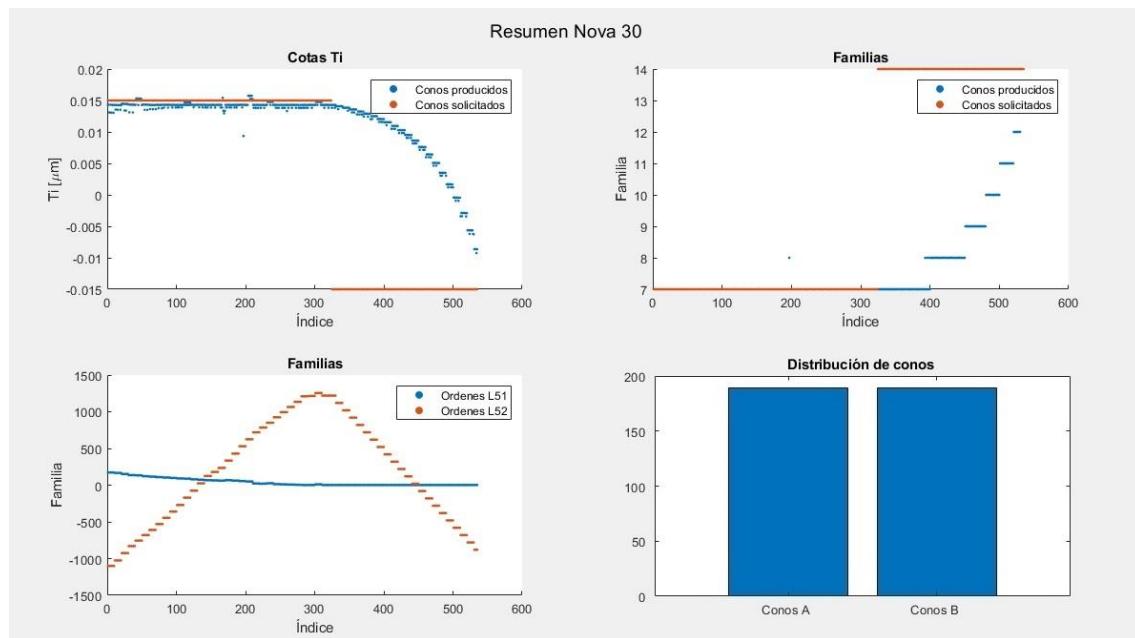


**ILUSTRACIÓN 213 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

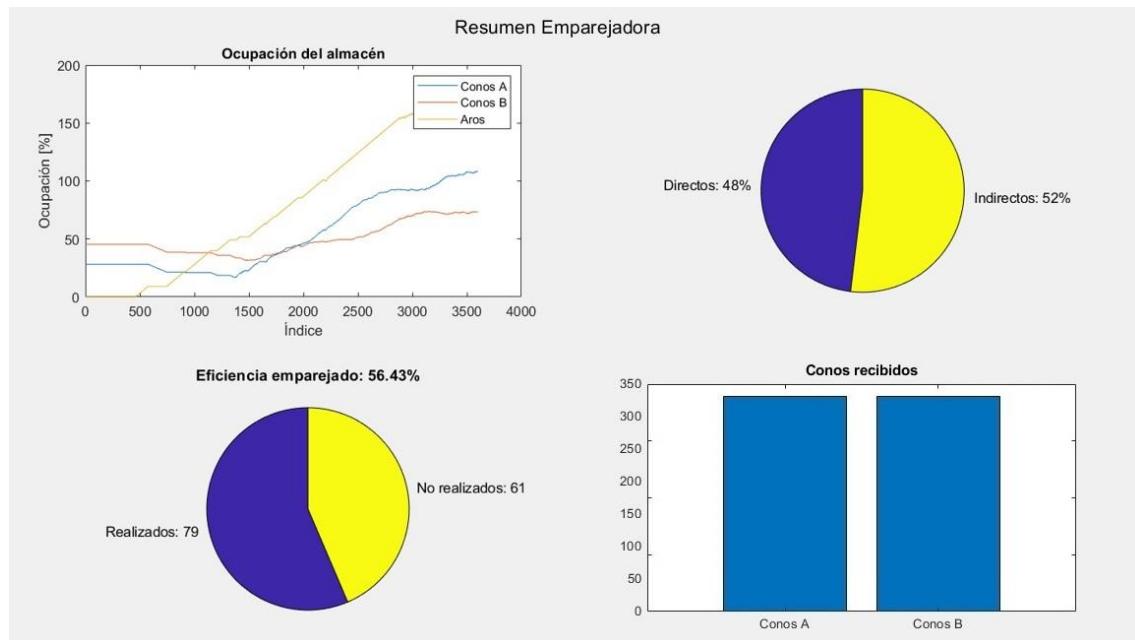


**ILUSTRACIÓN 214 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

**ILUSTRACIÓN 215 RESULTADO DE LA SIMULACIÓN****CAMBIO EN LA DISTRIBUCIÓN DE LOS CONOS****DISTRIBUCIÓN DE ONDA CUADRADA****ILUSTRACIÓN 216 INFORMACIÓN GENERAL PARA EL GEMELO DIGITAL**

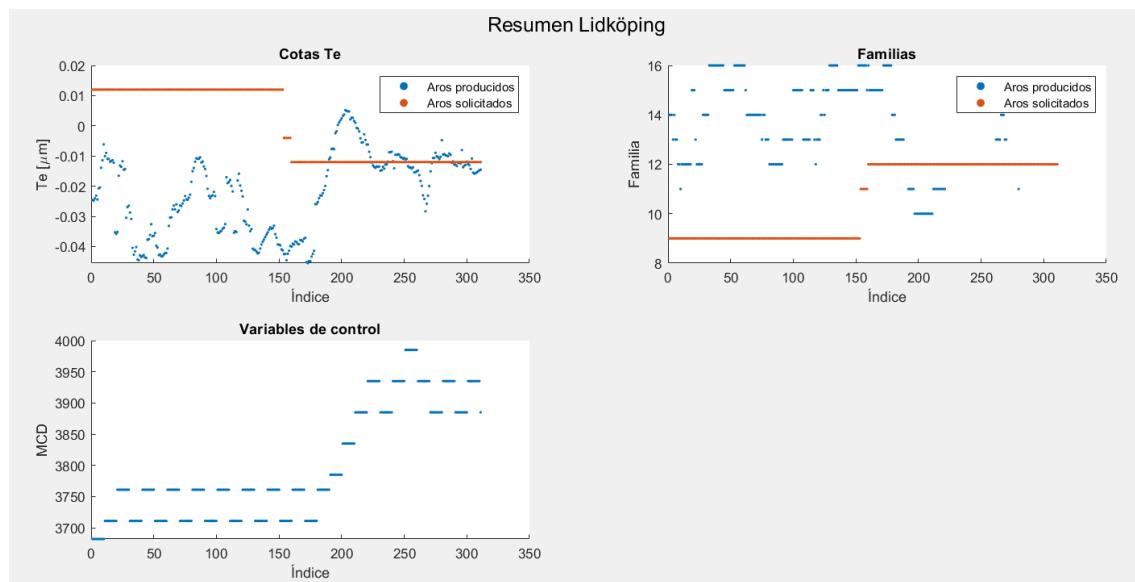


**ILUSTRACIÓN 217 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

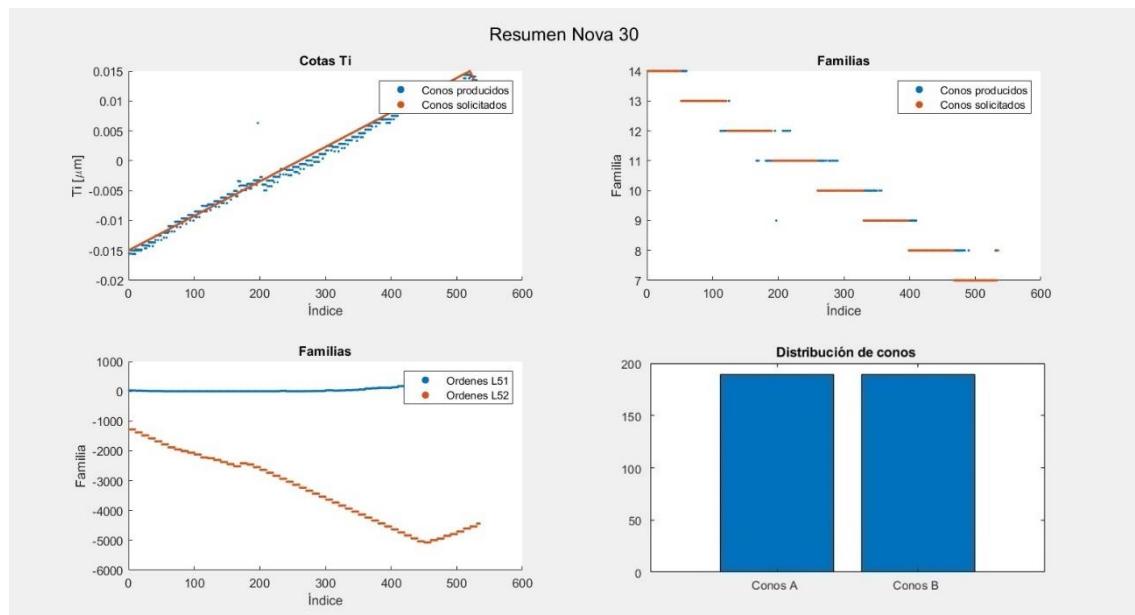


**ILUSTRACIÓN 218 RESULTADO DE LA SIMULACIÓN**

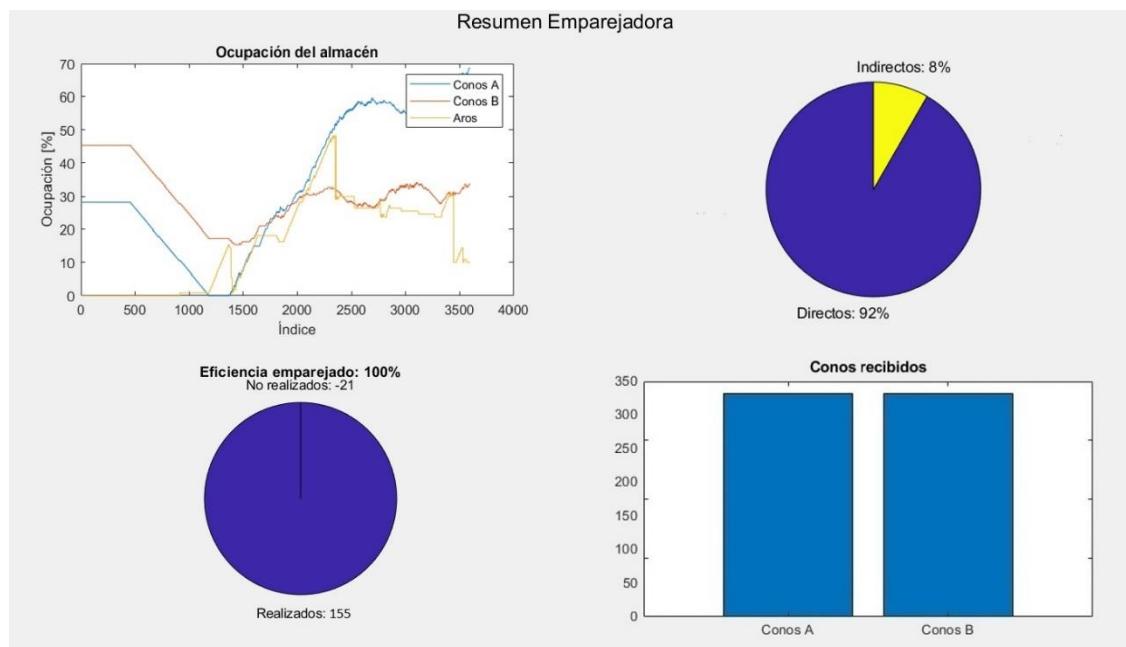
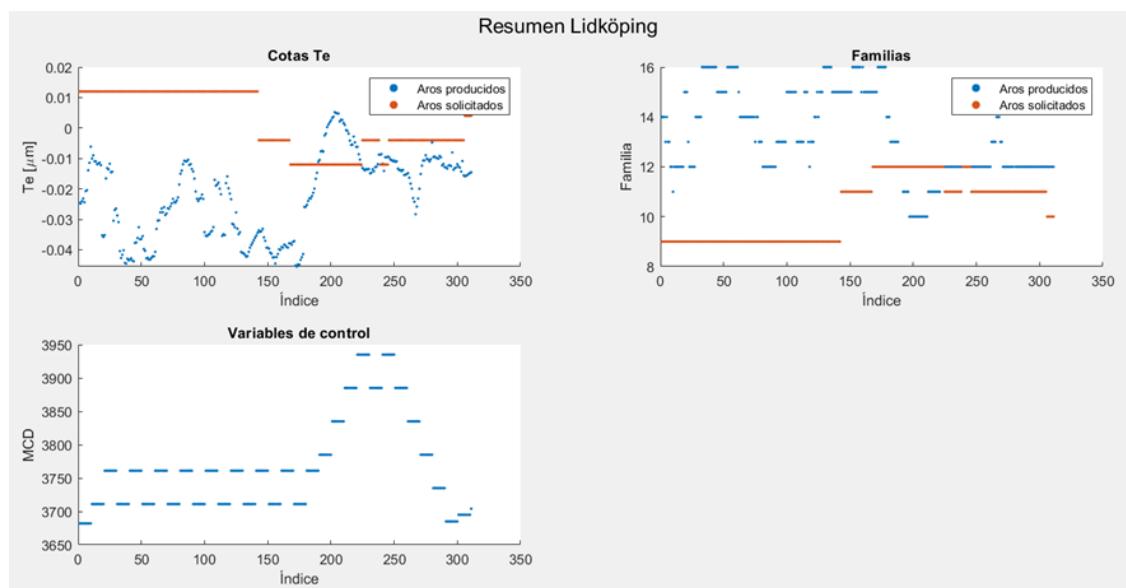
## DISTRIBUCIÓN EN DIENTE DE SIERRA

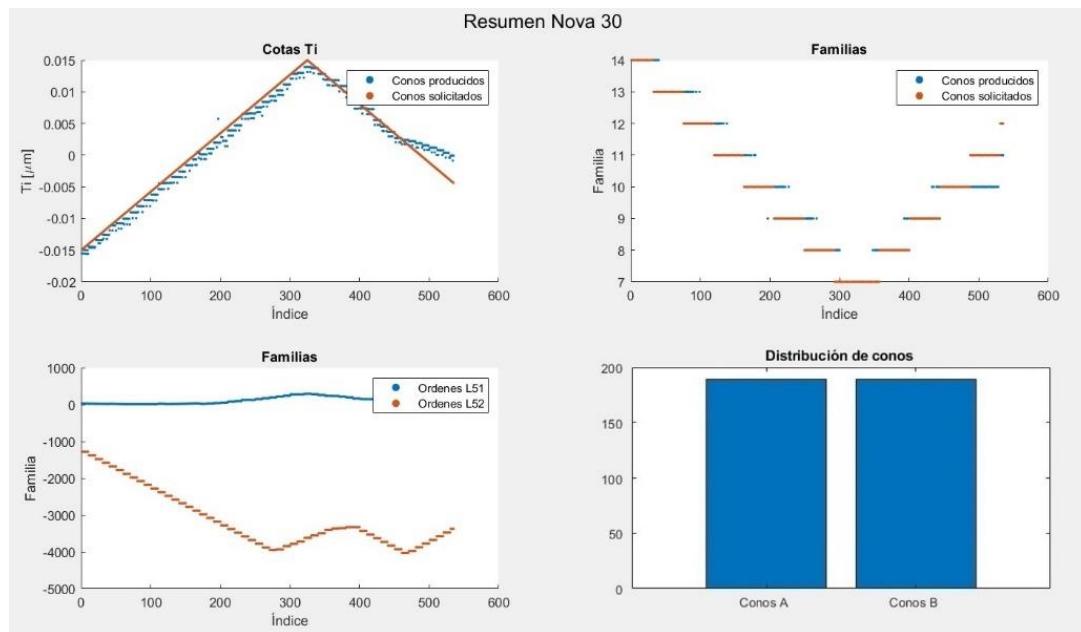


**ILUSTRACIÓN 219 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

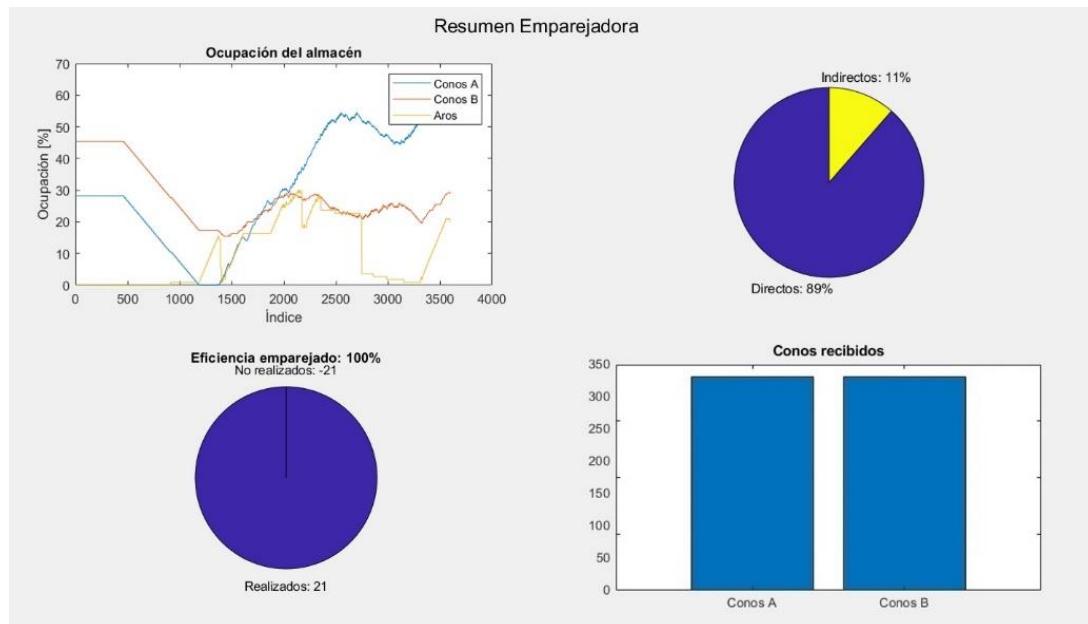


**ILUSTRACIÓN 220 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

**ILUSTRACIÓN 221 RESULTADO DE LA SIMULACIÓN****DISTRIBUCIÓN TRIANGULAR****ILUSTRACIÓN 222 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**

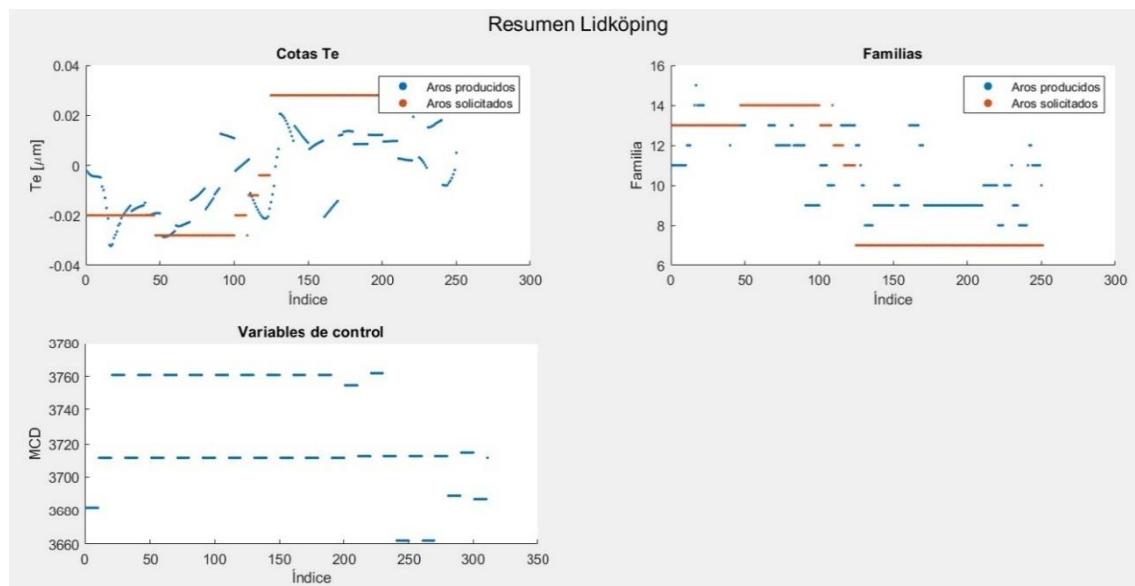


**ILUSTRACIÓN 223 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**

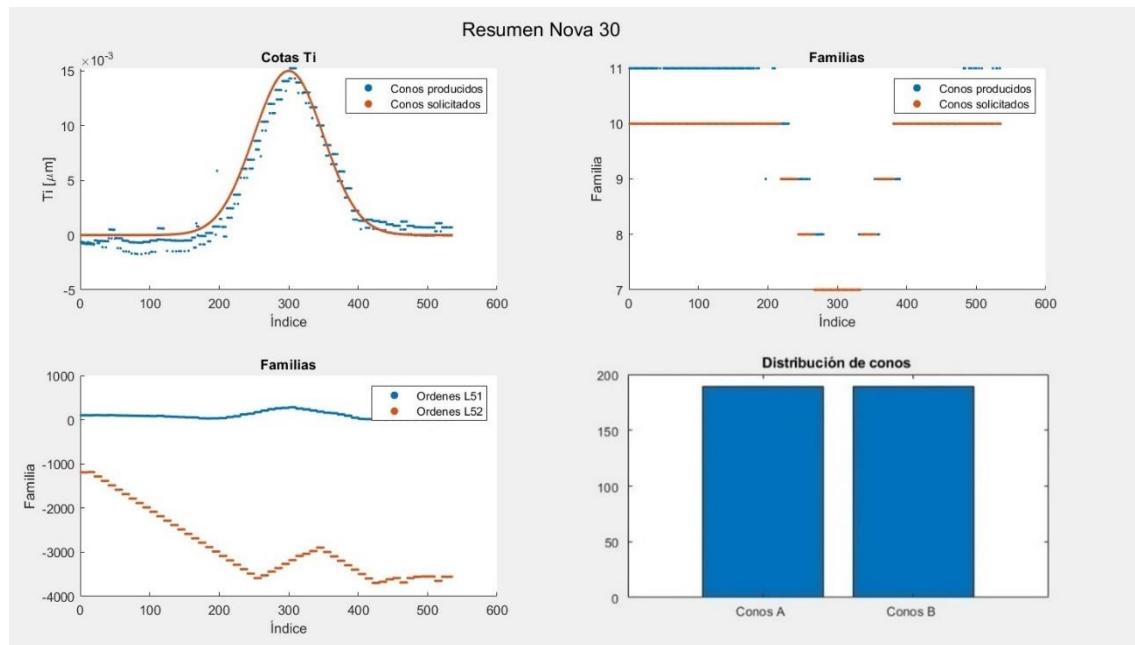


**ILUSTRACIÓN 224 RESULTADO DE LA SIMULACIÓN**

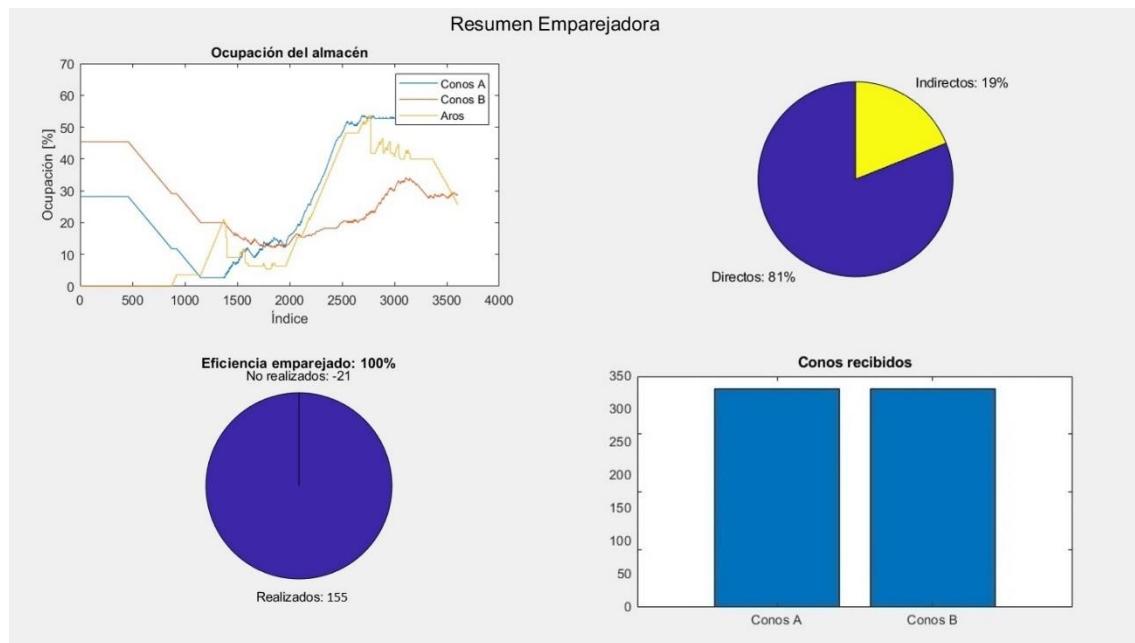
## DISTRIBUCIÓN GAUSSIANA



**ILUSTRACIÓN 225 RESUMEN DE DISTRIBUCIÓN DE AROS EN LA SIMULACIÓN**



**ILUSTRACIÓN 226 DISTRIBUCIÓN DE CONOS CON SU FAMILIA Y VARIABLES DE CONTROL**



**ILUSTRACIÓN 227 RESULTADO DE LA SIMULACIÓN**

## ANEXO 6 SCRIPTS

En este anexo se muestran algunos scripts que se han realizado para el desarrollo del gemelo digital nuevo.

### AROS

```

clear;          % Borra todas las variables del workspace
clc;           % Limpia la consola
close all;     % Cierra todas las figuras abiertas
tic;
%Para mezclar dos tablas en MATLAB, donde ambas tienen una columna común
%(por ejemplo, el DataMatrix de las piezas), puedes utilizar la función
%join o innerjoin dependiendo de cómo quieras combinar los datos. Si las
%dos tablas tienen algunas piezas en común y solo quieres mantener las
%filas que coinciden en ambas tablas, puedes usar innerjoin. Si prefieres
%conservar todas las filas y llenar con valores NaN donde no coinciden,
%utiliza outerjoin.

% Suponiendo que tienes dos tablas: tabla1 y tabla2
% y que ambas tienen una columna llamada 'DataMatrix'
%tabla_combinada = innerjoin(tabla1, tabla2, 'Keys', 'DataMatrix');
% Si quieres hacer una unión exterior para mantener todas las filas
%tabla_combinada = outerjoin(tabla1, tabla2, 'Keys', 'DataMatrix',
'MergeKeys', true);
%Ejemplo
% % Tabla 1
% tabla1 = table([1; 2; 3], {'A'; 'B'; 'C'}, 'VariableNames', {'DataMatrix',
'Maquina1'});
%
% % Tabla 2
% tabla2 = table([2; 3; 4], {'X'; 'Y'; 'Z'}, 'VariableNames', {'DataMatrix',
'Maquina2'});
%
% % Unión de las tablas
% tabla_combinada = innerjoin(tabla1, tabla2, 'Keys', 'DataMatrix');

% Lee el archivo CSV en una tabla
%T1 = readtable('Z3M06_data.xlsx');

% Nombre del archivo de salida
outputFile = 'miArchivo.xlsx';

% Verifica si el archivo ya existe y, si es así, lo elimina
if isfile(outputFile)
    delete(outputFile);
end

opts = detectImportOptions('Z3M06_data.txt');
opts = setvartype(opts, 'dm', 'char'); % 'dm' para leer como texto
% Por ejemplo, puedes elegir las variables específicas que quieras leer
opts.SelectedVariableNames = {'dm', 'timestamp', 'R115', 'R120', 'R121',
'R218', 'R280'}; %'R81',
'R62', 'R73', 'R74', 'R75', 'R76', 'R77', 'R78', 'R79', 'R98', 'R100', 'R101', 'R102', 'R

```

```

103','R104','R105','R110','R111','R112','R113','R114','R117','R118','R126','R
127','R128','R129','R130','R131','R132','R133','R134','R135','R136','R139','R
142','R143','R144','R145','R148','R152','R162','R170','R174','R175','R176','R
177','R178','R179','R180','R181','R182','R183','R201','R211','R227','R228','R
231','R232','R233','R249','R267','R270','R271','R321','R322','R323','R366','R
374','R379','R451','R452','R453','R480','R482','R481','R611','R632','R633','R
99','R202','R281','R53',}; % Especifica columnas
% Leer solo las primeras n filas si solo necesitas una muestra
%opts.DataLines = [1 1000]; % Leer las primeras 1000 filas
T1 = readtable('Z3M06_data.txt', opts);
%T2.dm = str2double(T2.dm); % Convertir a números no funciona bien!
T1_ordenada = sortrows(T1, 'timestamp');

% calcular deltas de R218 y R280 añadiendo columnas
% Calcular los incrementos entre elementos consecutivos
deltaR218 = [diff(T1_ordenada.R218);NaN]; % El primer valor será NaN porque
no hay incremento antes del primer elemento
% Añadir la columna de incrementos a la tabla
T1_ordenada.DeltaR218 = deltaR218;

% Calcular los incrementos entre elementos consecutivos
deltaR280 = [diff(T1_ordenada.R280);NaN]; % El primer valor será NaN porque
no hay incremento antes del primer elemento
% Añadir la columna de incrementos a la tabla
T1_ordenada.DeltaR280 = deltaR280;

umbral = -0.1; % Definir el umbral
%T1_ordenada(T1_ordenada.DeltaR218 < umbral, :) = []; % Eliminar las filas
donde 'ColumnaX' es menor que el umbral
%T1_ordenada(T1_ordenada.DeltaR218 == 0, :) = []; % Eliminar las filas donde
'ColumnaX' es igual a cero

%El problema de los números grandes truncados al leer un CSV se debe a que
%MATLAB puede interpretar esos valores como números en notación científica,
%lo que puede causar pérdida de precisión. Una solución es tratar esos
%números como texto en lugar de como valores numéricos, para asegurarte de
%que se lean correctamente y luego convertirlos en números de forma manual
%si es necesario.

%T3 = readtable('Z3M06_data.txt');

opts2 = detectImportOptions('Z3M21_2_data.txt');
opts2 = setvartype(opts2, 'dm', 'char'); % 'dm' para leer como texto
% Por ejemplo, puedes elegir las variables específicas que quieras leer
opts2.SelectedVariableNames = {'dm', 'COTA_TE_OR'}; % Especifica columnas
% Leer solo las primeras n filas si solo necesitas una muestra
%opts.DataLines = [1 1000]; % Leer las primeras 1000 filas
T2 = readtable('Z3M21_2_data.txt', opts2);

% Unión de las tablas
T3 = innerjoin(T1_ordenada, T2, 'Keys', 'dm');
%writetable(T3, 'miArchivo.txt', 'Delimiter', '\t'); % El delimitador '\t' es
para formato de texto tabulado
writetable(T3, outputFile);

% Encuentra los índices de cambio de muela según la condición en la columna
'Delta'
indicesCambio = find(T3.DeltaR218 >= 0 | T3.DeltaR218 <= -0.1);

```

```

% Añade el último índice para capturar hasta el final de la tabla
indicesCambio = [indicesCambio; height(T3) + 1];

% Elimina cualquier archivo previo de 'muela_*.xlsx' para empezar de cero
files = dir('muela_*.xlsx');
for k = 1:length(files)
    delete(fullfile(files(k).folder, files(k).name));
end

% Crea archivos separados para cada subconjunto entre cambios de muela
for i = 1:length(indicesCambio) - 1
    % Extrae el subconjunto de datos para la muela actual
    subTabla = T3(indicesCambio(i)+1:indicesCambio(i+1)-1, :);

    % Genera un nombre de archivo dinámico para cada muela
    nombreArchivo = ['muela_' num2str(i) '.xlsx'];

    % Guarda el subconjunto en un archivo Excel
    writetable(subTabla, nombreArchivo);
end

toc;

```

## CONOS

```

clear;      % Borra todas las variables del workspace
clc;        % Limpia la consola
close all;  % Cierra todas las figuras abiertas
tic;
%Para mezclar dos tablas en MATLAB, donde ambas tienen una columna común
%(por ejemplo, el DataMatrix de las piezas), puedes utilizar la función
%join o innerjoin dependiendo de cómo quieras combinar los datos. Si las
%dos tablas tienen algunas piezas en común y solo quieres mantener las
%filas que coinciden en ambas tablas, puedes usar innerjoin. Si prefieres
%conservar todas las filas y llenar con valores NaN donde no coinciden,
%utiliza outerjoin.

% Suponiendo que tienes dos tablas: tabla1 y tabla2
% y que ambas tienen una columna llamada 'DataMatrix'
%tabla_combinada = innerjoin(tabla1, tabla2, 'Keys', 'DataMatrix');
% Si quieres hacer una unión exterior para mantener todas las filas
%tabla_combinada = outerjoin(tabla1, tabla2, 'Keys', 'DataMatrix',
'MergeKeys', true);
%Ejemplo
% % Tabla 1
% tabla1 = table([1; 2; 3], {'A'; 'B'; 'C'}, 'VariableNames', {'DataMatrix',
'Maquina1'});
%
% % Tabla 2
% tabla2 = table([2; 3; 4], {'X'; 'Y'; 'Z'}, 'VariableNames', {'DataMatrix',
'Maquina2'});
%
% % Unión de las tablas
% tabla_combinada = innerjoin(tabla1, tabla2, 'Keys', 'DataMatrix');

```

```

% Lee el archivo CSV en una tabla
%T1 = readtable('Z3M06_data.xlsx');

% Nombre del archivo de salidaA
outputFileA = 'ElArchivoA.xlsx';

% Verifica si el archivo ya existe y, si es así, lo elimina
if isfile(outputFileA)
    delete(outputFileA);
end

% Nombre del archivo de salidaB
outputFileB = 'ElArchivoB.xlsx';

% Verifica si el archivo ya existe y, si es así, lo elimina
if isfile(outputFileB)
    delete(outputFileB);
end

opts = detectImportOptions('Z3M11_A_data.txt');
opts = setvartype(opts, 'dm', 'char'); % 'dm' para leer como texto
% Por ejemplo, puedes elegir las variables específicas que quieras leer
opts.SelectedVariableNames = {'dm', 'timestamp', 'L51', 'L52', 'R35', 'R75', 'R322'}; % Especifica columnas
% Leer solo las primeras n filas si solo necesitas una muestra
%opts.DataLines = [1 1000]; % Leer las primeras 1000 filas
T1 = readtable('Z3M11_A_data.txt', opts);
%T2.dm = str2double(T2.dm); % Convertir a números no funciona bien!
T1_ordenada = sortrows(T1, 'timestamp');

% Número de filas a eliminar
x = 3318;

% eliminar las últimas X filas
T1_ordenada(end-x+1:end, :) = [];

% disp('Tabla resultante:');
% disp(T1_ordenada);

% calcular deltas de R322 añadiendo columnas
% Calcular los incrementos entre elementos consecutivos
deltaR322 = [diff(T1_ordenada.R322);NaN]; % El primer valor será NaN porque
no hay incremento antes del primer elemento
% Añadir la columna de incrementos a la tabla
T1_ordenada.DeltaR322 = deltaR322;

opts = detectImportOptions('Z3M11_B_data.txt');
opts = setvartype(opts, 'dm', 'char'); % 'dm' para leer como texto
% Por ejemplo, puedes elegir las variables específicas que quieras leer
opts.SelectedVariableNames = {'dm', 'timestamp', 'L51', 'L52', 'R35', 'R75', 'R322'}; % Especifica columnas
% Leer solo las primeras n filas si solo necesitas una muestra
%opts.DataLines = [1 1000]; % Leer las primeras 1000 filas
T2 = readtable('Z3M11_B_data.txt', opts);
%T2.dm = str2double(T2.dm); % Convertir a números no funciona bien!
T2_ordenada = sortrows(T2, 'timestamp');

% Número de filas a eliminar
y = 3272;

```

```

% eliminar las últimas Y filas
T2_ordenada(end-y+1:end, :) = [];

% disp('Tabla resultante:');
% disp(T2_ordenada);

% calcular deltas de R322 añadiendo columnas
% Calcular los incrementos entre elementos consecutivos
deltaR322 = [diff(T2_ordenada.R322);NaN]; % El primer valor será NaN porque
no hay incremento antes del primer elemento
% Añadir la columna de incrementos a la tabla
T2_ordenada.DeltaR322 = deltaR322;

opts2 = detectImportOptions('Z3M21_1_A_data.txt');
opts2 = setvartype(opts2, 'dm', 'char'); % 'dm' para leer como texto
% Por ejemplo, puedes elegir las variables específicas que quieras leer
opts2.SelectedVariableNames = {'dm', 'COTA_TI_IR'}; % Especifica columnas
% Leer solo las primeras n filas si solo necesitas una muestra
%opts.DataLines = [1 1000]; % Leer las primeras 1000 filas
T3 = readtable('Z3M21_1_A_data.txt', opts2);

opts2 = detectImportOptions('Z3M21_1_B_data.txt');
opts2 = setvartype(opts2, 'dm', 'char'); % 'dm' para leer como texto
% Por ejemplo, puedes elegir las variables específicas que quieras leer
opts2.SelectedVariableNames = {'dm', 'COTA_TI_IR'}; % Especifica columnas
% Leer solo las primeras n filas si solo necesitas una muestra
%opts.DataLines = [1 1000]; % Leer las primeras 1000 filas
T4 = readtable('Z3M21_1_B_data.txt', opts2);

% Unión de las tablas
T5A = innerjoin(T1_ordenada, T3, 'Keys', 'dm');
%writetable(T3, 'miArchivo.txt', 'Delimiter', '\t'); % El delimitador '\t' es
para formato de texto tabulado
writetable(T5A, outputFileA);

% Unión de las tablas
T6B = innerjoin(T2_ordenada, T4, 'Keys', 'dm');
%writetable(T3, 'miArchivo.txt', 'Delimiter', '\t'); % El delimitador '\t' es
para formato de texto tabulado
writetable(T6B, outputFileB);

% Concatenar las tablas verticalmente
tablaCombinada = vertcat(T5A, T6B);

% Exportar a un archivo Excel
nombreArchivo = 'Datos Unidos AB.xlsx';
writetable(tablaCombinada, nombreArchivo);

disp(['Archivo Excel creado: ', nombreArchivo]);

```

**PÉRDIDA DE PRECISIÓN (Código)**

```

% Cargar los datos del archivo Excel
data = readtable('ElArchivoA.xlsx');

% Seleccionar las variables de entrada (inputs) y la salida (output)
inputs = data(:, {'L51', 'L52', 'R35', 'R75', 'DeltaR322'});
output = data.COTA_TI_IR;

% Configuración
interval_size = 1500; % Tamaño de los intervalos para entrenamiento y prueba

% Dividir los datos en conjuntos de intervalos
n_intervals = floor(size(inputs, 1) / interval_size);
rmse_train_once = [];
rmse_train_iterative = [];

% Estrategia 1: Entrenar una vez hasta cierto punto y probar el resto
% Entrenar con el primer segmento completo
train_end = interval_size; % Número de muestras para el entrenamiento inicial
X_train_once = inputs(1:train_end, :);
y_train_once = output(1:train_end, :);
gpr_once = fitrgp(X_train_once, y_train_once, 'KernelFunction', 'exponential');

% Probar el resto de los intervalos
for i = 2:n_intervals
    X_test_once = inputs((i-1)*interval_size+1:i*interval_size, :);
    y_test_once = output((i-1)*interval_size+1:i*interval_size, :);

    y_pred_once = predict(gpr_once, X_test_once);
    rmse_once = sqrt(mean((y_test_once - y_pred_once).^2));
    rmse_train_once = [rmse_train_once; rmse_once];
end

% Estrategia 2: Entrenar en un intervalo y probar en el siguiente
for i = 1:n_intervals-1
    % Entrenar en el intervalo actual
    X_train_iterative = inputs((i-1)*interval_size+1:i*interval_size, :);
    y_train_iterative = output((i-1)*interval_size+1:i*interval_size, :);

    gpr_iterative = fitrgp(X_train_iterative, y_train_iterative, 'KernelFunction', 'exponential');

    % Probar en el siguiente intervalo
    X_test_iterative = inputs(i*interval_size+1:(i+1)*interval_size, :);
    y_test_iterative = output(i*interval_size+1:(i+1)*interval_size, :);

    y_pred_iterative = predict(gpr_iterative, X_test_iterative);
    rmse_iterative = sqrt(mean((y_test_iterative - y_pred_iterative).^2));
    rmse_train_iterative = [rmse_train_iterative; rmse_iterative];
end

% Graficar los resultados
figure;
plot(2:n_intervals, rmse_train_once, '-o', 'DisplayName', 'Entrenar una vez y probar en intervalos');
hold on;
plot(1:n_intervals-1, rmse_train_iterative, '-x', 'DisplayName', 'Entrenar por intervalo');
xlabel('Número de intervalo de prueba');
ylabel('Error cuadrático medio (RMSE)');
title('Comparación de RMSE: Entrenamiento único vs. por intervalos');
legend('show');
grid on;

```

## SIMULACION GLOBAL GD NUEVO DESARROLLADO INSPIRADO EN EL GD ANTERIOR

El código principal (simulación global) es similar al caso antiguo de partida realizado en el proyecto Fandango. Las funciones que utilizan este código principal no son las mismas que en el gemelo digital anterior para una mejor adaptación a los datos nuevos:

[Fuente: proyecto Fandango](#)

```

close all;
clear all;
tic
%Información globales de la simulación
cargar_informacion_general;
%Script con parámetros globales para ajustar la simulación

%Leer intervalos con mayor número de piezas y cargar la información
intervalo_M06 = leer_continuidad_rectificadora('Intervalos_NuevaTablaM06');
%Leer mayor intervalo de M06
intervalo_M11 =
leer_continuidad_rectificadora('Intervalos_Datos Unidos AB Nuevo');
%Leer mayor intervalo de M11

M06_data = leer_datos_rectificadora('NuevaTablaM06', intervalo_M06);
%Leer información del intervalo de M06
M11_data = leer_datos_rectificadora('Libro3', intervalo_M11);
%Leer información del intervalo de M11

%Leer algunas variables iniciales necesarias para inicializar la simulación
%(Te inicial, distribuciones en almacen)
[situacion_init, indices_grupos] = buscar_situacion_inicial(M06_data);

%Nivelar la producción hasta un ratio de conos:aros de 2:1
[M06_data, M11_data] = nivelar_produccion(M06_data, M11_data,
situacion_init);
M06_actual = M06_data;
%Las variables "actual" contienen la información de las piezas esperando a
ser
M11_actual = M11_data;
%incluidas en la simulación. Por lo tanto evolucionan.

%Leer los tiempos de ciclo y los tiempos de respuesta
[t_M11_A, t_M11_B, t_M06, t_M21_3] = leer_tiempos_ciclo;
%Tiempos de ciclo
[T_aros, T_conos] = leer_tiempos_respuesta;

%Inicializar tiempo total de la simulación
t_total = 5*60*60;
%Unidades en segundos

%Inicializar variables auxiliares
info_M06 = inicializar_M06(numero_factores_M06, intervalo_ajuste_M06,
M06_data, situacion_init);           %Información de la máquina M06
info_M11 = inicializar_M11(num_fact_conosA, num_fact_conosB, int_ajuste_M11,
M11_data, patron_conos);    %Información de la máquina M11

```

```

info_M21 = inicializar_M21(distribuciones, situacion_init, indices_grupos);
%Información de la máquina M21
corresp_Familias_Te = readtable('InputNuevos/correspondencias_Grupos-
Te.xlsx');
%Equivalencias entre familias y cota
Te
aros_enviados =
array2table(zeros(0,3),'VariableNames',{'Te','Familia','T_llegada'});
%Tabla que almacena los aros en camino a M21
corresp_Familias_Ti = readtable('InputNuevos/correspondencias_Grupos-
Ti.xlsx');
%Equivalencias entre familias y cota
Ti
conos_enviados =
array2table(zeros(0,4),'VariableNames',{'Ti','Familia','Tipo','T_llegada'});
%Tabla que almacena los conos en camino a M21

%Inicializar los videos de control de la simulación
if grabar_videos
    [v1, v2, v3] = inicializar_videos;
else
    v1 = 0; v2 = 0; v3 = 0;
end

%El bucle principal actualiza el estado de las estaciones M06, M11 y M21 en
%función de sus tiempos de ciclo. Cada iteración supone un avance de 5"
%hasta que se recorre todo el intervalo temporal.
for i=0:5:t_total

    %Actualizar estación M06
    [M06_actual, info_M06] = actualizar_M06(i, t_M06, M06_actual, info_M06,
intervalo_ajuste_M06, info_M21, corresp_Familias_Te);
    aros_enviados = envio_aros(info_M06, corresp_Familias_Te, T_aros,
aros_enviados); %Actualizar envío de aros. La variable
"aros_enviados" guarda los aros que están de camino a la emparejadora

    %Actualizar estación M11
    [M11_actual, info_M11] = actualizar_M11(i, t_M11_A, t_M11_B, M11_actual,
info_M11, int_ajuste_M11, corresp_Familias_Ti);
    conos_enviados = envio_conos(info_M11, corresp_Familias_Ti, T_conos,
conos_enviados); %Actualizar envío de conos. La variable
"conos_enviados" guarda los conos que están de camino a la emparejadora

    %Actualizar estación M21
    [info_M21, conos_enviados, aros_enviados] = actualizar_M21(t_M21_3,
info_M21, info_M06, aros_enviados, conos_enviados, corresp_Familias_Te,
estrategia_emparejado);

    %Si no quedan piezas por procesar, terminar la simulación
    if isempty(conos_enviados) && isempty(aros_enviados) &&
info_M21.t_ocupada < -60
        break
    end

    %Si se desea grabar un video, registrar los frames
    if grabar_videos
        evaluar_resultados(info_M06, info_M11, info_M21, grabar_videos, v1,
v2, v3, 0);
    end
end

```

```
%Evaluar resultados mediante gráficos
if mostrar_figuras
    evaluar_resultados(info_M06, info_M11, info_M21, grabar_videos, v1, v2,
v3, mostrar_figuras);
end
toc
%close all;
```