



UNIVERSIDAD DEL BÍO BÍO

FACULTAD DE CIENCIAS EMPRESARIALES
DEPARTAMENTO DE SISTEMA DE INFORMACION

APLICACIÓN DE TÉCNICAS DE DATA MINING AL RENDIMIENTO ACADÉMICO DEL PRIMER CURSO DE PROGRAMACIÓN DE COMPUTADORES

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL EN INFORMATICA

Autor

Francisco Rodríguez Morales

Profesor Guía

Christian Vidal Castro

Concepción, Julio 2013

Dedicatoria

Esta sección, aunque se exhibe al principio de la memoria ha sido la última en ser escrita. Me es un poco complicado expresar tantos sentimientos que se asoman en estas instancias, aún más difícil es resumir en pocas palabras todo lo vivido en el transcurso de mi carrera y poder agradecer a los que han estado conmigo siempre.

Después de este largo camino recorrido que no ha sido fácil de llevar, me encuentro aquí a punto de terminar una etapa importante en mi vida, sinceramente y de corazón, doy gracias a mis padres que siempre me han apoyado y me dieron la oportunidad de estudiar, inculcándome desde niño el valor por el conocimiento, la sabiduría, los buenos principios y valores y por sobre todo una buena educación, también doy gracias a todos los que me han apoyado en todo el tiempo que he estado en mi carrera, no doy nombres, para no dejar a nadie en el tintero, pero en general, muchas gracias amigos y familiares, su apoyo fue fundamental, para terminar esto.

Resumen

En este trabajo se aplicaron técnicas de Data Mining a datos del primer curso de programación de nuestra Universidad, utilizando un proceso de “Knowledge Discovery in Databases” a la información relacionada, con el objetivo de adquirir conocimiento útil acerca del comportamiento de los alumnos que aprueban y reprueban este curso.

El rendimiento académico está limitado por diferentes factores. Es de gran utilidad determinar cuáles son los atributos más incidentes en el desempeño de los estudiantes, lo que se pretende mostrar con el proceso de “Knowledge Discovery in Databases” es justamente esto; obtención de conocimiento útil acerca del comportamiento de los alumnos que aprueban y reprueban el curso, a través de la determinación y generación de reglas que precisamente indiquen las variables más influyentes.

En este proyecto se han aplicado enfoques y técnicas de Minería de Datos en varios experimentos que han permitido crear estos modelos de predicción del rendimiento de los alumnos. Cabe mencionar, que los distintos modelos han sido desarrollados por la herramienta de software llamada “WEKA”. Se ha seguido este proceso por todas sus etapas, desde la selección de los datos, hasta la misma interpretación de los resultados obtenidos a partir de estos datos.

Este trabajo aporta positivamente al desempeño del curso y de cada alumno en particular. Ya que, tomar la decisión adecuada en el instante de tiempo preciso por parte del profesor que imparte el curso de programación, puede hacer la diferencia entre que un alumno haya aprobado o fracasado el curso. En efecto, con el conocimiento nuevo adquirido se va ayudar al profesor a tomar esta mejor decisión.

Abstract

In this paper data mining techniques applied to data from the first programming course of our university, using a process of "Knowledge Discovery in Databases" to related information, in order to acquire useful knowledge about the behavior of students passing and flunk this course.

Academic performance is limited by different factors. Is useful to determine which attributes are more incidents in student performance, which is intended to show the process of "Knowledge Discovery in Databases" is just that; obtaining useful knowledge about the behavior of students who pass and fail the course, through the identification and generation of rules that precisely indicate the most influential variables.

In this project we have implemented approaches have been applied and data mining techniques in several experiments that have created these models for predicting student performance. Worth mentioning that the various models have been developed by the software tool called "Weka". It has followed this process for all stages, from the selection of data to the same interpretation of the results obtained from these data.

This work contributes positively to the performance of the course and of each individual student. Since, taking the right decision at the precise instant of time by the teacher who teaches the programming course, can make the difference between a student has passed or failed the course. Indeed, with the newly gained knowledge will help the teacher to make this better decision.

Índice General

1	INTRODUCCION.....	1
2	DEFINICION DEL PROYECTO	3
2.1	Justificación.....	3
2.2	Aporte.....	4
2.3	Objetivo General.....	4
2.4	Objetivos Específicos.....	5
2.5	Límites.....	5
2.6	Metodología.....	5
3	MARCO TEORICO.....	8
3.1	Proceso de descubrimiento del conocimiento en Bases de Datos.....	8
3.1.1	Introducción	8
3.1.2	El proceso KDD según los autores Fayyad, Piatetsky-Shapiro	9
3.1.2.1	Definición	9
3.1.2.2	Etapas del proceso KDD según Fayyad, Piatetsky-Shapiro.....	12
3.1.3	El proceso KDD según los autores Han y Kamber	14
3.1.3.1	Definición	14
3.1.3.2	Etapas del proceso KDD según Han y Kamber.....	15
3.1.4	Conclusión	18
3.2	Data Mining o Minería de datos	19
3.2.1	Introducción e Historia	19
3.2.2	Data Mining y su relación con los Data Warehouse	21
3.2.3	Minería de datos y sus necesidades	23
3.2.3.1	Objetivos del Data Mining	25
3.2.3.2	Ventajas del Data Mining.....	26
3.2.4	El Proceso de Data Mining.....	26
3.2.5	Tipos de modelos y enfoques algorítmicos de Data Mining	28
3.2.5.1	Modelos predictivos.....	29

3.2.5.1.1	Clasificación.....	29
3.2.5.1.2	Regresión.....	30
3.2.5.2	Modelos descriptivos.....	30
3.2.5.2.1	Agrupamiento o Clustering.....	31
3.2.5.2.2	Asociación.....	31
3.2.5.2.3	Correlación.....	32
3.2.6	Técnicas de Data Mining.....	33
3.2.6.1	Redes neuronales artificiales (RNA).....	33
3.2.6.1.1	Estructura.....	35
3.2.6.1.2	Topología.....	42
3.2.6.1.3	Mecanismos de aprendizaje.....	42
3.2.6.2	Arboles de decisión (AD).....	48
3.2.6.3	Naïve Bayes (NB).....	48
3.2.7	Algunas aplicaciones de Data Mining.....	49
3.2.7.1	En el gobierno.....	49
3.2.7.2	En los clubes deportivos.....	50
3.2.7.3	En investigaciones espaciales.....	50
3.2.7.4	En la universidad.....	51
3.2.7.5	En la empresa.....	52
3.2.8	Herramientas de Data Mining.....	53
3.2.8.1	Introducción.....	53
3.2.8.2	WEKA (Waikato Environment for Knowledge Analysis).....	56
3.2.8.2.1	Funcionamiento de WEKA.....	57
3.2.8.2.2	Beneficios y problemas.....	59
3.2.8.3	KEEL (Knowledge Extraction based on Evolutionary Learning).....	60
3.2.8.3.1	Funcionamiento de KEEL.....	60
3.2.8.3.2	Principales Características.....	62
3.2.8.4	Otras.....	64
3.2.8.4.1	De tipo libre.....	64
3.2.8.4.2	De tipo comercial.....	65

3.2.9	Ejemplos	66
3.2.9.1	Ejemplo 1 (Descriptivo): Análisis de la cesta de compra [2].....	66
3.2.9.2	Ejemplo 2 (Predictivo): Análisis de créditos bancarios [2]	67
4	PROCESO DE EXTRACCION DE CONOCIMIENTO.....	69
4.1	Elección de Enfoque, Técnicas y Algoritmos.....	69
4.1.1	Herramienta escogida.....	69
4.1.2	Enfoques utilizados	71
4.1.3	Técnicas y Algoritmos empleados	71
4.2	Documentación KDD.....	71
4.2.1	Selección de datos	72
4.2.2	Pre-procesamiento de los datos	73
4.2.3	Transformación de los datos.....	76
4.2.4	Minería de datos	86
4.2.5	Interpretación/Evaluación de resultados.....	90
5	RESULTADOS OBTENIDOS	99
5.1	Experimento 1: Validación Cruzada utilizando todos los atributos.....	99
5.2	Experimento 2: Validación cruzada utilizando todos los atributos y considerando el costo de clasificación.....	100
5.3	Experimento 3: Validación Cruzada usando los atributos hasta el Certamen 1	101
6	PROTOTIPO O APLICACION.....	103
6.1	Diseño de interfaz y navegación	103
7	CONCLUSION	108
7.1	Conclusión de acuerdo a los Objetivos Específicos	108
7.2	Conclusión personal.....	109
8	BIBLIOGRAFIA	110
	ANEXOS.....	113
	ANEXO 1: Glosario de Términos	113
	ANEXO 2: Resultados algoritmo J48	115
	ANEXO 3: Archivo Utilizado en Minería de Datos.....	118

Índice Tablas

Tabla 3.2.1: Datos de las cestas de compra.....	66
Tabla 3.2.2: Datos para un análisis de riesgo en créditos bancarios.	67
Tabla 4.2.1: Descripción de las variables.....	76
Tabla 4.2.2: Etiquetado de la variable "Carrera"	76
Tabla 4.2.3: Etiquetado de la variable "PsuPaa".....	77
Tabla 4.2.4: Etiquetado de la variable "PuntajeMat".....	77
Tabla 4.2.5: Etiquetado de la variable "Nota"	78
Tabla 4.2.6: Etiquetado de la variable "Colegio"	78
Tabla 4.2.7: Etiquetado de la variable "TiempoEntrar".....	79
Tabla 4.2.8: Etiquetado de la variable "Asistencia"	79
Tabla 4.2.9: Etiquetado de la variable "Semestre".....	80
Tabla 4.2.10: Etiquetado de la variable "Profesor"	80
Tabla 4.2.11: Etiquetado de la variable "Certamen1".....	81
Tabla 4.2.12: Etiquetado de la variable "Certamen2".....	81
Tabla 4.2.13: Etiquetado de la variable "Certamen3".....	82
Tabla 4.2.14: Etiquetado de la variable "NotaTest"	82
Tabla 4.2.15: Etiquetado de la variable "Trabajo".....	83
Tabla 4.2.16: Etiquetado de la variable "NotaPresentacion".....	84
Tabla 4.2.17: Etiquetado de la variable "Examen".....	84
Tabla 4.2.18: Etiquetado de la variable "NotaFinal"	85
Tabla 4.2.19: Etiquetado de la variable "TerminoRamo"	85
Tabla 4.2.20: Etiquetado de la variable "PrimeraSegunda"	86
Tabla 4.2.21: Reglas obtenidas usando OneR y considerando el costo de la clasificación.	90
Tabla 4.2.22: Reglas (de tipo Aprobó) obtenida usando Prism y considerando el costo de clasificación.	91
Tabla 4.2.23: Árbol obtenido usando J48 y considerando el costo de clasificación.....	92
Tabla 4.2.24: Reglas obtenidas usando el algoritmo J48.	95
Tabla 4.2.25: Reglas generadas por el algoritmo SimpleCart.	96

Tabla 4.2.26: Reglas obtenidas del algoritmo Ridor.....	97
Tabla 5.1.1: Validación Cruzada de todos los atributos.....	99
Tabla 5.2.1: Validación Cruzada de todos los atributos considerando el costo de clasificación.....	100

Índice Figuras

Ilustración 3.1.1: Jerarquía del conocimiento (Molina, 1998).....	9
Ilustración 3.1.2: Etapas del proceso KDD (Fayyad, Smyth, Piatetsky-Shapiro, 1996).....	12
Ilustración 3.1.3: Fases del proceso KDD (Han y Kamber, 2006).....	15
Ilustración 3.2.1: El ciclo de la vida de los datos (Andrés Eyherabide, 2012).	20
Ilustración 3.2.2: Data Warehouse y su relación con la minería de datos.	23
Ilustración 3.2.3: Funcionamiento general de una neurona artificial (Palmer y Montaña, 1999).	35
Ilustración 3.2.4: Activación Tipo Escalon (Izaurieta y Saavedra).....	36
Ilustración 3.2.5: Activación Tipo Sigmoidea (Izaurieta y Saavedra).....	37
Ilustración 3.2.6: Red Monocapa (Izaurieta y Saavedra).	39
Ilustración 3.2.7: Red Multicapa (Izaurieta y Saavedra).	40
Ilustración 3.2.8: Encuesta de las herramientas utilizadas frecuentemente (Junio 2012)..	55
Ilustración 3.2.9: Ave WEKA.....	57
Ilustración 3.2.10: Inicio del software WEKA.	58
Ilustración 3.2.11: Pantalla de inicio de KEEL.	61
Ilustración 4.2.1: Grafico del atributo “NotaFinal” que se encuentra balanceado.	87
Ilustración 4.2.2: Árbol obtenido por el algoritmo J48.	94
Ilustración 6.1.1: Layout principal de la aplicación.....	103
Ilustración 6.1.2: Validación para el formato correcto.	104
Ilustración 6.1.3: Validación para el valor máximo en los campos de puntajes.	104
Ilustración 6.1.4: Validación para el valor mínimo en PSU.....	105
Ilustración 6.1.5: Validación campo vacío.	105
Ilustración 6.1.6: Validación para el valor máximo en los campos de notas.....	105
Ilustración 6.1.7: Botones de Borrar y Resultado.....	105
Ilustración 6.1.8: Mensaje de confirmación para borrar todos los campos.	106
Ilustración 6.1.9: Mensaje para cuando el alumno no clasifica en ninguna clase.	106
Ilustración 6.1.10: Mensaje para cuando el alumno puede aprobar.	106
Ilustración 6.1.11: Mensaje para cuando el alumno puede reprobar.....	107

1 INTRODUCCION

Extraer conocimiento a partir de datos es un proceso que se viene haciendo a lo largo de la historia y que en la actualidad está teniendo una gran importancia debido, entre otras cosas, a la manera exponencial que crecen las bases de datos, almacenando grandes volúmenes de información que se tienen que manejar. Es así como surge el interés y la necesidad de explorar nuevas formas de extracción automática de conocimiento a partir de la información disponible.

Específicamente en el presente trabajo se busca extraer conocimiento de los datos y aportar al desempeño de los estudiantes. Mejorar el rendimiento académico es muy provechoso tanto para los alumnos, para los profesores, y como para la misma Universidad, ya que se puede conseguir una nueva metodología por parte de los profesores para implementar sus técnicas de enseñanzas, mejorando en creces el rendimiento final de su curso.

El objetivo principal de este proyecto es adquirir conocimiento útil y novedoso aplicando diversas técnicas de minería de datos todo en relación a la información con las calificaciones obtenidas por alumnos en el primer curso de programación de las carreras de Informática de la Facultad de Ciencias Empresariales (Sede Concepción).

Se estima que la extracción de patrones (minería) de los datos ocupa solo el 15% - 20% del esfuerzo total del proceso de Knowledge Discovery in Databases (KDD), siendo las etapas que más consumen, la selección y pre-procesado de los datos, es por eso, que se aplica más esfuerzo en esas etapas. Para posteriormente aplicar de forma segura y correcta las técnicas y algoritmos de minería de datos. Aumentando la precisión y confianza de los datos.

En el capítulo 2 del proyecto, trata de definir el proyecto, especificando su justificación, la aportación de esta tesis, el objetivo general y, las limitantes que existen, la metodología empleada a lo largo del proyecto y los objetivos específicos. Dejando en forma clara y concisa lo que se pretende finalmente.

En el capítulo 3, va todo lo relacionado con el marco teórico, es decir, el conocimiento mínimo que hay que tener de los conceptos y problemas a tratar, para que en los capítulos siguientes se entienda de que es lo que se está explicando y que es lo que pretende buscar.

En el capítulo 4, se argumentan las elecciones de los enfoques, técnicas y algoritmos de minería de datos empleados en este problema. Además, se documenta todo el proceso KDD, explicando cómo se obtuvieron las variables, el pre-proceso que se les ha aplicado, la transformación, la minería de datos y finalmente la interpretación de los resultados obtenidos una vez finalizado este proceso de extracción de conocimiento.

En el capítulo 5, se muestran los resultados obtenidos después de la ejecución de ciertos experimentos, en los cuales fueron aplicadas las diversas técnicas de minería de datos con el fin de encontrar patrones o reglas de interés. Todos los resultados y las conclusiones inferidas en base de los distintos análisis que se han realizado, han sido explicados en este capítulo.

Para finalizar, en el capítulo 6 se muestran algunos layout's de la aplicación con su explicación correspondiente, para dar a conocer el funcionamiento del prototipo y todo lo que esta conlleva.

2 DEFINICION DEL PROYECTO

2.1 Justificación

Las asignaturas de primer año son importantes y difíciles para la mayoría de los alumnos que están ingresando a la educación superior y las asignaturas relacionadas con la programación de computadores no es la excepción en las carreras de informática.

Este proyecto se enfoca justamente en las asignaturas de primer año y que buscan el aprendizaje de un lenguaje de programación en las carreras de Ingeniería Civil en Informática e Ingeniería de Ejecución en Computación e Informática.

Sin duda parecen ser una de las primeras asignaturas en la carrera que realmente necesitan ser estudiadas y aprendidas de forma correcta, ya que lo que se enseña es básicamente la base de todos los ramos donde tengamos que programar en algún lenguaje específico, por ende, es que hay que poner énfasis en este ramo y tratar de mejorar el rendimiento académico de los alumnos que están inscritos en los primeros cursos de programación o encontrar ciertas formas que ayuden a que se comprenda mejor el contenido que se pasa en aquellos ramos, obteniendo así buenos resultados para los alumnos y para el profesor que imparte dicho ramo.

Algunos alumnos reprueban estos cursos sin recibir una ayuda a tiempo, incluso hasta terminan desertando la carrera por culpa de esta situación, ya que muchos piensan que al no aprender la materia de un ramo como este, quizás para adelante todo sea igual y malo para ellos, esto refleja que hay que darle mucha importancia a la forma en que se imparte y enseña la programación en los primeros cursos de las carreras de informáticas de nuestra universidad, es por eso que es vital que en lo posible todos los alumnos aprendieran de forma eficiente y adecuada lo que se enseña en programación, la mejor manera para poder solucionar este problema es que el profesor se dé cuenta de que alumnos van mal encaminados en el curso, ya sea porque les ha ido mal en los certámenes, o están faltando demasiado a clases o no van a la ayudantías que se les disponen.

Ante este problema, es que se decide implementar a través de las técnicas de minería de datos un proceso que corrobore esta información, seguramente los profesores pueden intuir que métodos son los más apropiados para poder impartir los ramos de programación y que se obtengan resultados beneficiosos, pero que mediante un estudio y muestra de modelos, complemente el conocimiento que se ya tiene y se convierta en un conocimiento útil y novedoso para utilizar después adecuadamente.

2.2 Aporte

La minería de datos sirve para predecir y describir ciertos patrones, utilizando diversos métodos que nos ayuden a tener una idea y derivar cuales variables son las que más van a influir en el desempeño de los alumnos.

Este proyecto, intenta aportar al estudio de este problema determinando variables que inciden en el desempeño de los alumnos en el primer curso de programación. Mediante la aplicación de técnicas de “Data Mining” se podría determinar en que fallan los alumnos, buscar algunos patrones de comportamiento que nos lleven a concluir cuales son las principales falencias que más afectan al rendimiento académico de los alumnos. De esta manera un profesor podría tomar decisiones correctas para poder ayudar al estudiante que se encuentran en riesgo de reprobado, ya sea recomendándole clases de reforzamiento, prácticas y/o ayudantías obligatorias.

2.3 Objetivo General

Aplicar un proceso de “Knowledge Discovery in Databases” o “KDD” a la información relacionada con las calificaciones obtenidas por alumnos en el primer curso de programación de las carreras de Informática de la Facultad de Ciencias Empresariales sede Concepción, con el objetivo de adquirir conocimiento útil acerca del comportamiento de los alumnos que aprueban y reprobado este curso.

2.4 Objetivos Específicos

- Definir y aplicar un proceso de “Data Mining” a la información relacionada con las calificaciones obtenidas por alumnos en el primer curso de programación de las carreras Ingeniería Civil en Informática e Ingeniería de Ejecución en Computación e Informática.
- Definir los enfoques y técnicas y herramientas de “Data Mining” más pertinentes a los objetivos establecidos.
- Establecer variables que determinen el comportamiento, en términos de la calificación final, de los alumnos del primer curso de programación.
- Interpretar y demostrar la utilidad del conocimiento obtenido, mediante la construcción de un prototipo que ayude a la gestión del curso.

2.5 Límites

Una limitante de este trabajo, en primera instancia, es que está orientado solo a los cursos de programación de las carreras informáticas de la Facultad de Ciencias Empresariales (Sede Concepción), esto debido a que los datos de los alumnos que se recolectaron por medio de registro académico y profesores, fueron de alumnos que ingresaron en dicha sede, y que pertenecían a las carreras de informáticas. Es por eso, que la respuesta será más precisa y con reglas más detalladas.

Se aplica a alumnos que ingresaron a las carreras de informática entre el periodo 2000 – 2012, demasiados datos, que a simple vista los patrones son difíciles de captar o percibir por el ojo humano, pero que se hace todo más fácil utilizando la minería de datos.

2.6 Metodología

La metodología a utilizar en este trabajo es el proceso de extracción de conocimiento en grandes bases de datos, que ha sido adaptado para nuestro problema. El KDD (Knowledge Discovery in Databases) es un proceso iterativo e interactivo que combina la

experiencia en un problema con una variedad de técnicas de análisis de datos tradicionales y tecnologías avanzadas de aprendizaje.

El objetivo es descubrir patrones y relaciones en los datos que puedan ser usados para hacer predicciones válidas.

Consta de una serie de etapas que han sido desarrolladas en secuencia, estas son explicadas brevemente a continuación:

- Recopilación y filtrado de datos: En esta etapa se reúne toda la información de los alumnos, seleccionamos los factores que puedan afectar en el rendimiento final del estudiante.

Otra función de esta fase es que se filtran los datos (ya que pueden existir valores, incorrectos, nulos, no válidos, etc), se obtienen muestras de los mismos o también se pueden reducir el número de valores posibles.

Finalmente toda esta información se debe componer en un único conjunto de datos. Es sin duda una etapa que puede demandar demasiado tiempo.

- Selección de Variables: Se preparan los datos para poder aplicar, posteriormente, las técnicas de minería de datos, también se seleccionan, se limpian y se transforman los datos que se quieren analizar de los alumnos, estas tres son tareas típicas del pre-procesamiento, luego elegiremos las variables más influyentes.

Además la selección se incluye una fusión horizontal y vertical y se aplican técnicas de rebalanceo de datos ya que generalmente estos conjuntos de datos tienen problemas de dimensionalidad y desbalanceo.

- Minería de datos: En esta etapa se obtiene un modelo de conocimiento; escogeremos varios enfoques y técnicas de la minería de datos para generar distintos modelos y poder predecir el desempeño que obtendrá, si reprobará o aprobará el curso de programación.

Los algoritmos utilizados deben ser evaluados y comparados para así obtener los mejores resultados.

- Interpretación y Evaluación: Después de obtener los modelos, se debe proceder a analizarlos y validarlos. Los mejores resultados que se hayan obtenidos de estos modelos, se utilizarán en la detección a tiempo del fracaso del alumno en el curso.

Si ninguno de los modelos alcanza los resultados que esperamos, se deberá alterar alguno de las etapas anteriores para generar nuevos modelos, esto hace que el proceso de extracción de conocimiento en grandes bases de datos sea un “proceso iterativo”.

3 MARCO TEORICO

3.1 Proceso de descubrimiento del conocimiento en Bases de Datos

3.1.1 Introducción

Un término muy utilizado y sin duda el más vinculado con la minería de datos es la extracción o el descubrimiento de conocimientos en bases de datos de gran tamaño (**Knowledge Discovery in Databases, KDD**). En demasiadas ocasiones ambos términos (Minería de datos y KDD) se han usado de igual manera, aunque existen notables diferencias entre ellos. Así KDD se usa para referirse a un proceso que está compuesto por una serie de etapas, mientras que la minería de datos es solo una fase del proceso KDD.

El proceso del Descubrimiento del conocimiento en Base de Datos o KDD es un método tradicional de convertir datos en conocimiento, puesto en 1989 cuando se da la necesidad de una metodología de análisis inteligente de datos.

Entre las definiciones que se encuentran para este proceso, hay algunos autores que definen a este análisis con cinco etapas, otros que lo definen con menos o incluso más pasos, a continuación, se procede a explicar las exposiciones de varios autores importantes en este tema. Abarcando desde la comprensión y preparación de los datos hasta la interpretación y explotación de los resultados obtenidos a partir de los mismos.

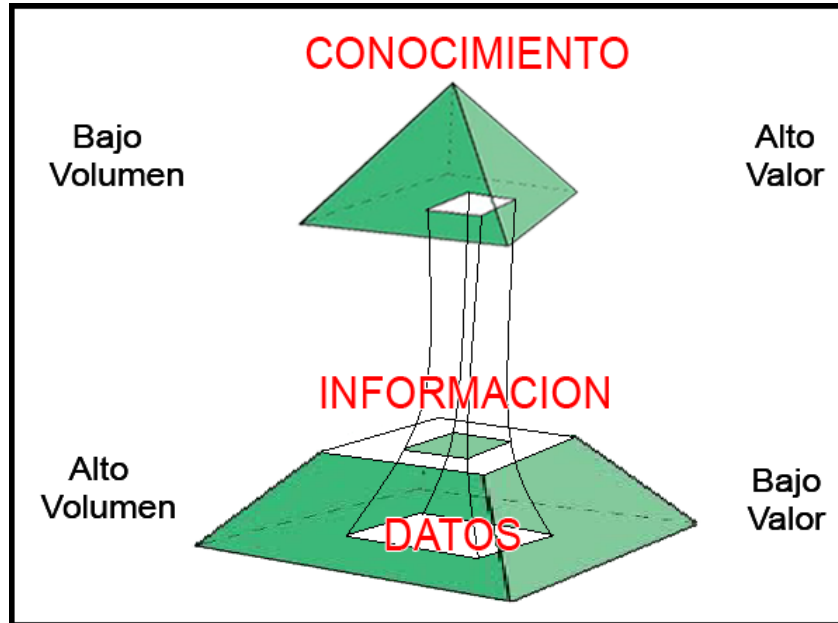


Ilustración 3.1.1: Jerarquía del conocimiento (Molina, 1998).

3.1.2 El proceso KDD según los autores Fayyad, Piatetsky-Shapiro

3.1.2.1 Definición

Fayyad¹, Piatetsky-Shapiro² y Smyth³ definen al término KDD, como “*El proceso no trivial de identificar patrones válidos, nuevos, potencialmente útiles y en última instancia comprensible en los datos*” [1996].

Propiedades de la definición descrita anteriormente:

- **Valido:** Hace referencia a que los patrones deben seguir siendo precisos para datos nuevos, y no solo para aquellos que han usado en su obtención.
- **Nuevos:** Que aporte algo desconocido tanto para el sistema y preferiblemente para el usuario.

¹ Usama Fayyad es el actual CDO (Chief Data Officer) y vicepresidente ejecutivo de investigación y soluciones de datos estratégicas en Yahoo!, Sunnyvale, CA 94088, Estados Unidos (Fax: +1 (734) 314-6892; Teléfono: (206) 236-2074, email: usama@fayyad.com).

² Gregory Piatetsky-Shapiro es presidente de KDnuggets, que proporciona análisis y consultoría de minería de datos, Boston, Estados Unidos (Teléfono: 617-264-9914; email: editor1@kdnuggets.com).

³ Padhraic Smyth es profesor del Departamento de Ciencias de la Computación y director del Centro de Aprendizaje de Máquinas y Sistemas Inteligentes, University of California, Irvine, CA 92697-3435 (Teléfono: (949) 824 2558; Fax: (949) 824 4056; email: widrow@stanford.edu).

- Potencialmente útil: La información debe conducir a acciones que reporten algún tipo de beneficio para el usuario.
- Comprensible: La extracción de patrones no comprensibles va a dificultar o a imposibilitar su revisión, validación, interpretación y su uso en la toma de decisiones pertinentes. De hecho una información que no es comprensible, no proporciona conocimiento útil.

También estos profesores definen los conceptos nombrados anteriormente en una forma que puede explicitarse matemáticamente, y que también llevan a una definición operativa del conocimiento.

- Datos: Un conjunto de hechos “D”.
- Patrón: Una expresión “E”, en algún lenguaje “L” que describe un subconjunto de los datos “D”, siempre que sea más sencilla que la simple enumeración de todos los hechos que componen “D”.
- Validez: Esta propiedad se define como una función “C(E, D)” que asigna una calificación, es decir, un número al patrón.
- Novedad: Una función “N(E, D)” que devuelve verdadero si el patrón no es una recombinación de patrones ya detectados o falso en caso contrario.
- Utilidad: Se representa por una función que califica la utilidad “U(E,D)”. Los patrones nos permiten realizar o decidir una acción.
- Comprensibilidad: Fayyad sugiere como medida cuantitativa la sencillez del patrón, se representa nuevamente con una función “S(E, D)” que asigna un valor.

Todo esto lleva finalmente al importante concepto de “medida de interés” o “Interestingness Measures”.

Entonces aparece un nuevo término, el cual es definido como una combinación de Validez, Novedad, Utilidad y Comprensibilidad que permite valorar y clasificar los patrones.

- Interestingness: Se representa por la función “I(E, C, D, N, U, S)”.

Al haber intervención humana en el concepto mencionado previamente, se puede decir que la medida del interés es fundamental para la definición del **conocimiento** final que se obtiene.

- Conocimiento: Un patrón “E” se llama conocimiento si su medida del interés “I” supera un cierto umbral “u” definido por el mismo usuario.

El conocimiento lo forman aquellos patrones que se aprenden a detectar y que además se guardan, ya que estos se aplican a los nuevos datos y, por tanto, se puede predecir el comportamiento de los sucesos o fenómenos que nos rodean.

En el primer estado de arte del área sobre el área se dice:

“La mayoría de los trabajos previos en KDD, se centraban en la etapa de Minería de Datos. Sin embargo, los otros pasos son de considerable importancia para el éxito de las aplicaciones de KDD en la práctica” [Fayyad y otros, 1996].

Señalando claramente lo importante de incluir en esta metodología el **pre-procesamiento** de los datos.

Estos autores definen este proceso con cinco etapas o pasos, las cuales son las siguientes: Selección, Pre-procesamiento, Transformación, Minería de Datos e Interpretación/Evaluación, tal cual se muestra en la Ilustración 3.1.2.1.

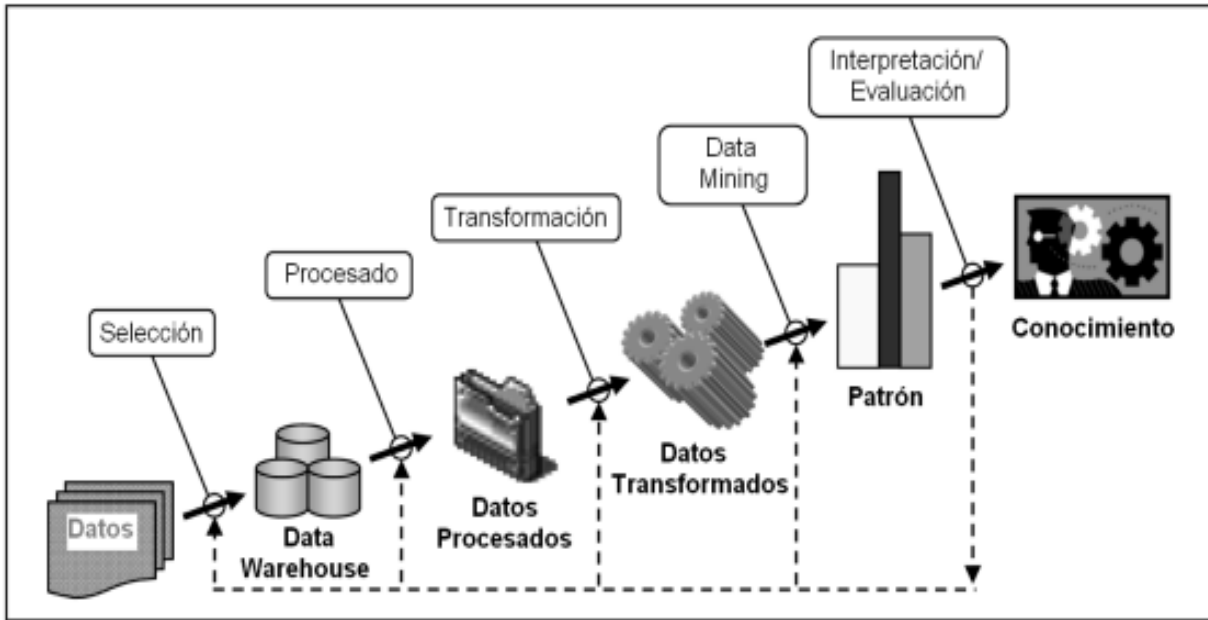


Ilustración 3.1.2: Etapas del proceso KDD (Fayyad, Smyth, Piatetsky-Shapiro, 1996).

Estos pasos aplicados de una manera iterativa e interactiva aseguran que el conocimiento que se extraiga sea útil. El objetivo es descubrir patrones y relaciones en los datos que puedan ser usados para hacer predicciones válidas acerca del tema que nos compete.

3.1.2.2 Etapas del proceso KDD según Fayyad, Piatetsky-Shapiro

A continuación se explican cada una de las cinco etapas que constituyen el proceso KDD, según estos autores:

1. Selección de datos: Después de entender la problemática y haber definido los objetivos, se deben seleccionar los datos, en esta etapa se elige el conjunto de datos objetivo sobre los que se elabora el análisis para el problema que deseamos resolver. Es muy importante en este paso unificar los datos, ya que pueden proceder de distintas fuentes.
2. Pre-procesamiento de los datos: El objetivo de esta etapa es garantizar la calidad de los datos que se van analizar, ya que de esto depende la calidad del conocimiento que luego descubriremos, preparando y limpiando los datos extraídos de las diferentes fuentes de datos en una forma transportable. En este

paso se incorporan múltiples tareas, tales como, el filtrado de individuos atípicos, la eliminación de ruido, el manejo de valores ausentes o la normalización de los datos. Obteniéndose al final una estructura de datos adecuada para su posterior transformación.

En efecto, esta etapa muchas veces es descuidada pero, sin embargo, es de suma importancia para el resultado final, dado que grandes cantidades de datos son recopilados por medio de métodos automáticos.

3. Transformación de los datos: En esta fase consiste en alterar o modificar la estructura de los datos, a una estructura apropiada, con el fin de facilitar el análisis de los mismos. Eso incluye consideraciones como la transformación del esquema original de los datos a otros esquemas (tabla única, desnormalización, etc.), la reducción de dimensiones para llevar adelante el trabajo con un número reducido de variables, la eliminación de columnas que varían juntas (aggregation), o técnicas más sofisticadas (clustering o análisis de componentes esenciales).

Se requiere un buen conocimiento del problema con que se trata y además una buena intuición que pueden marcar la diferencia entre el éxito o fracaso en el descubrimiento del conocimiento. Consolidando los datos de una forma necesaria para la siguiente etapa.

4. Minería de datos: Es el paso esencial donde se aplican diversos métodos inteligentes con el fin de extraer ciertos **patrones** previamente desconocidos, válidos, nuevos, potencialmente útiles y comprensibles y que están contenidos u ocultos en los datos. Esta es la etapa de “descubrimiento” dentro del proceso KDD, paso consistente en el uso de algoritmos concretos que producen patrones a partir de los datos pre-procesados.

Se ha de seleccionar una técnica de modelado acorde al problema, teniendo en cuenta el objetivo, cabe destacar, que todas las técnicas tienen un conjunto de parámetros que deciden las características del modelo a generar. La selección de los parámetros es un proceso iterativo y se basa solamente en los resultados generados.

5. Interpretación/Evaluación: Es la última etapa del proceso KDD, se identifican los patrones obtenidos que de verdad son interesantes y luego se evalúa y se interpreta el conocimiento extraído en la fase anterior contemplando tres criterios importantes: precisión, claridad, e interés.

De todo lo dicho por estos autores, concluyen en que el conocimiento es muy útil e importante dentro de lo que se hace a diario en esta vida, además se disponen de diferentes medios para aproximarse a él y obtener patrones interesantes para numerosos campos.

3.1.3 El proceso KDD según los autores Han y Kamber

3.1.3.1 Definición

La Extracción de conocimiento está principalmente relacionado con el proceso KDD, que según los autores Han⁴ y Kamber⁵ se refiere al *“Proceso no-trivial de descubrir conocimiento e información potencialmente útil dentro de los datos contenidos en algún repositorio de información” [2001].*

Básicamente, para ellos, el descubrimiento del conocimiento en las bases de datos está compuesto por 4 pasos, que son: limpieza e integración (recuperar en la base de datos, los datos relevantes para el análisis), selección y transformación (preparar los datos), minería de datos (construir modelos descriptivos/predictivos) y evaluación del modelo (encontrar los modelos descriptivos/predictivos que de mejor manera solucionen el problema), como se aprecia en la Ilustración 3.1.3.1:

⁴ Jiawei Han es profesor del Departamento de Ciencias de Computación, Universidad de Illinois en Urbana-Champaign, Urbana, IL 61801, Estados Unidos (Fax: (217) 265-6494; Telefono: (217) 333-6903; email: hanj@cs.uiuc.edu).

⁵ Usama Fayyad es el actual CDO (Chief Data Officer) y vicepresidente ejecutivo de investigación y soluciones de datos estratégicas en Yahoo!, Sunnyvale, CA 94088, Estados Unidos (Fax: +1 (734) 314-6892; Telefono: (206) 236-2074, email: usama@fayyad.com).

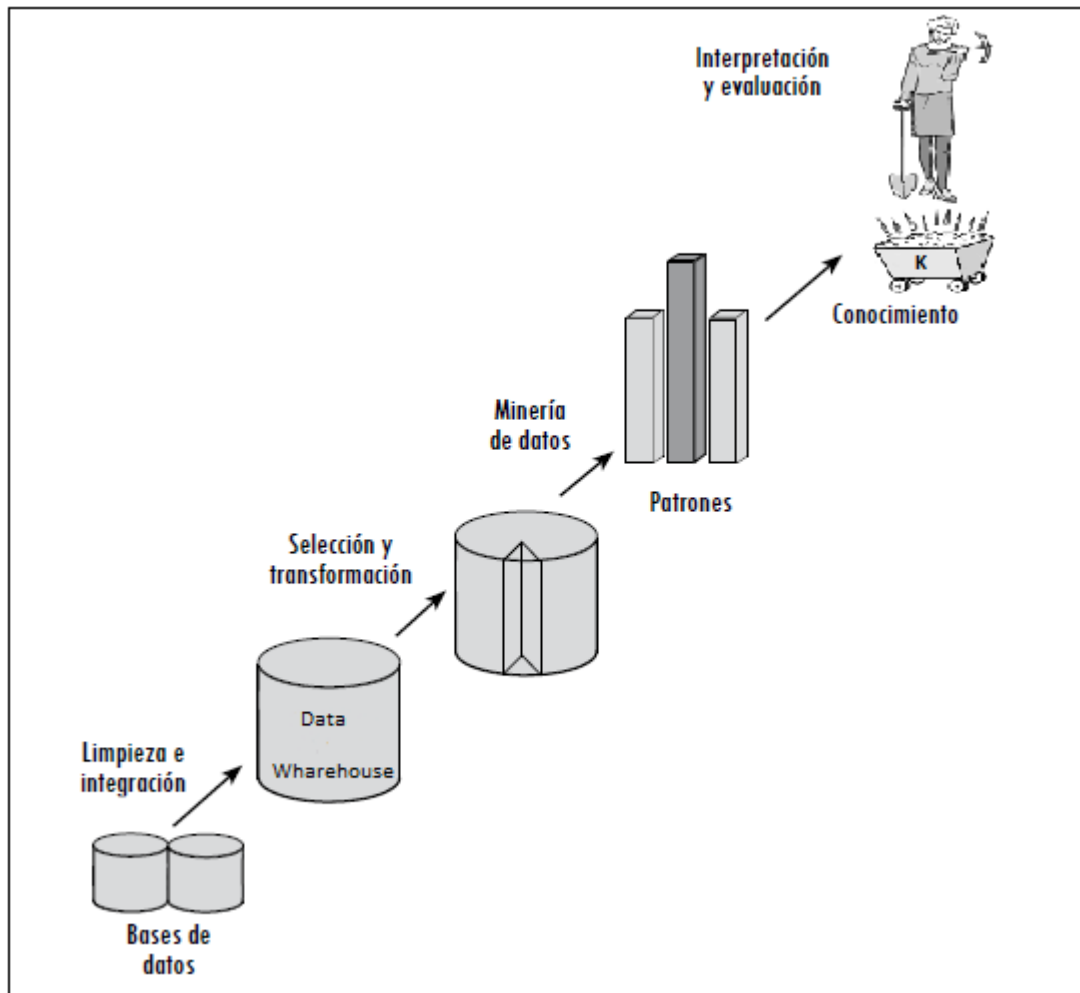


Ilustración 3.1.3: Fases del proceso KDD (Han y Kamber, 2006).

3.1.3.2 Etapas del proceso KDD según Han y Kamber

A continuación se explican cada una de las cuatro etapas que constituyen el proceso KDD, según estos autores:

1. Limpieza e integración de los datos: Es el procesamiento de tratamiento de los datos ruidosos, erróneos, faltantes o irrelevantes, y la integración de múltiples fuentes de datos en una única fuente para la próxima etapa.

Se limpian los valores nulos mediante técnicas, tales como:

- Ignorar la tupla: se aplica cuando el valor de la etiqueta es nulo, ignorando toda una fila o registro. Es eficiente usar cuando el porcentaje de valores nulos para varios atributos es considerable en relación a los demás.
- Llenar manualmente el valor nulo: Se usa cuando la cantidad de datos es pequeña ya que consume demasiado tiempo.
- Usar una constante global para llenar el valor ausente: Aquí se reemplaza el valor nulo por alguna constante pero no es muy efectivo ya que la solución del algoritmo de data mining puede obtener de forma errónea la solución.
- Usar el valor más probable: Se puede obtener un valor más probable para predecir valores nulos, esto se aplica mediante arboles de decisión o la aplicación de regresión.

Se disminuye el ruido y la inconsistencia en los datos usando distintos métodos:

- Suavización por media: Cada valor en un grupo es reemplazado por el valor promedio del grupo.
- Suavización por mediana: Cada valor en un grupo es reemplazado por la mediana del grupo.
- Suavización por límites: Cada valor en un grupo es reemplazado por los valores límites, obviando los valores límites de cada grupo.
- Normalización de datos: En particular, se usa para tratar la inconsistencia en los datos, verificando las violaciones en las dependencias funcionales entre atributos y valores ilógicos en los mismos.

Se integran los datos de diversas fuentes, combinándose en un único repositorio de datos, las fuentes pueden ser diversas bases de datos o archivos.

2. Selección y transformación de los datos: En esta etapa se extraen los datos destacados, seleccionando las variables más determinantes en el problema. La selección de datos puede ser de forma horizontal y se realiza un muestreo de los datos, habiendo cuatro tipos de muestreo (aleatorio simple, aleatorio estratificado, de grupos y exhaustivo).

También puede haber una selección de los datos de forma vertical, seleccionando los atributos más relevantes en base a algún criterio. Otra selección, es la de eliminación de claves candidatas, estas son variables de códigos de información, nombre y apellidos, teléfonos, etc.

Luego se transforman los datos, consolidando los datos en una forma adecuada para luego ser introducido en el algoritmo de data mining. Una tarea de la transformación es la construcción de nuevos atributos, en los casos en que los atributos no contribuyan con suficiente poder predictivos por sí mismos.

Dentro de la transformación de los datos, está la discretización de los datos, es decir, transformar valores numéricos en atributos continuos o discretos, todo esto con el fin de hacer modificaciones en los tipos de los datos, para ayudar el uso de las técnicas que requieran tipos de datos específicos.

3. Minería de datos: Es la etapa más característica del proceso KDD, y es por eso que muchas veces se tiende a utilizar esta fase para nombrar todo el proceso. El objetivo es generar nuevo conocimiento que pueda utilizar el usuario. Se construye un modelo basado en los datos previamente recopilados. Luego de obtener los patrones se pueden usarse para obtener predicciones.

La etapa de Data Mining se divide, a su vez, en otros tres pasos, estas decisiones se toman antes de empezar el proceso:

- Determinar qué tipo de tarea o enfoque de Data Mining es más apropiada para el caso.
 - Elegir el tipo de modelo y técnica para realizar la tarea.
 - Elegir el algoritmo de minería de datos más adecuado que resuelva la tarea y obtener el tipo de modelo que andamos buscando.
4. Interpretación/Evaluación: En la etapa de interpretación y evaluación, se inicia con la validación del modelo obtenido, verificando que las conclusiones que arroja sean válidas y suficientemente satisfactorias. Si el modelo no alcanza los

resultados esperados, se debe volver a modificar alguno de los pasos anteriores y repetir el proceso o parte de él, para poder originar un nuevo modelo.

Debido a la existencia de voluminosas bases de datos conteniendo gran cantidad de estos mismo, es que en las organizaciones las decisiones importantes se toman en base a la intuición y experiencia del que decide, más que considerando la rica información almacenada, es por esto que mediante el proceso KDD se intenta solucionar dicha situación con el fin de obtener información útil y valiosa.

3.1.4 Conclusión

Además de las fases descritas y en las que concuerdan todos los autores, frecuentemente se incorpora o se toma en cuenta una fase previa de análisis de las necesidades de la organización y definición del problema, en la que se decretan los objetivos. También es usual incorporar una etapa final, donde los resultados obtenidos se añaden al negocio para la realización de acciones comerciales u otros.

El proceso de descubrimiento del conocimiento (KDD) es un área que está tomando mucha importancia dado el crecimiento actual de las bases de datos (incluyendo bases de datos relacionales, bases de datos de objetos, entre otras), y dada la capacidad del hardware utilizable para procesar los datos.

Hay que tener en cuenta que el KDD no es un producto de software, sino un proceso compuesto de varias etapas muy importantes y que hacen enriquecer aún más este análisis teniendo en cuenta la tendencia con la que crecen las bases de datos y la utilidad que brinda el proceso KDD. Hoy en día están apareciendo varias herramientas con una gran cantidad de librerías que ayudan en cada uno de estos pasos para conseguir datos y que finalmente nos lleven a la obtención del conocimiento y su posterior difusión.

3.2 Data Mining o Minería de datos

3.2.1 Introducción e Historia

La idea de Data Mining o minería de datos (en español) no es nueva. Ya desde los años sesenta los estadísticos manejaban términos como “data fishing”, “data mining” o “data archaeology” con la idea de hallar correlaciones. A comienzos de los años 80, Rakesh Agrawal⁶, Gio Wiederhold⁷, entre otros, empezaron a utilizar y darle importancia cada vez más a este término, dando la posibilidad a que las empresas se dedicaran a ofrecer servicios utilizando la minería de datos. A finales de los 80 solo eran un par de empresa las que se beneficiaban con esta tecnología, con el pasar de los años fue creciendo exponencialmente el número de empresas que se dedican a esto, hoy en día son muchas y variadas las organizaciones que ofrecen distintas soluciones, utilizando la minería de datos como herramienta principal.

Esta tecnología ha sido un buen punto de encuentro entre personas pertenecientes al ámbito académico y al de los negocios. Intentando ayudar a comprender el contenido de grandes bases de datos.

La minería de datos se refiere al proceso que intenta descubrir patrones en grandes volúmenes de conjuntos de datos y que surge por la aparición de nuevas necesidades, necesidades que se dan ante el aumento del volumen y variedad de información que se encuentra informatizada en las bases de datos y sobre todo por el reconocimiento de un nuevo potencial: **el valor de los datos**. [2]

De una forma general, los datos pasan de ser un producto a ser una materia prima, que se tiene que pulir y explotar para poder alcanzar el conocimiento. Así a través del conocimiento conseguido, se pueden tomar las mejores decisiones para una organización determinada o para el problema que se tiene a resolver. Todo esto depende de los encargados en la toma de decisiones, los cuales tienen que utilizar el conocimiento

⁶ Rakesh Agrawal es miembro técnico en los laboratorio de búsqueda recién fundados en Microsoft, 1065 La Avenida, Mountain View, CA 94043, Estados Unidos (Fax: +1 (650) 693-4000, email: ragrawal@acm.org).

⁷ Gio Wiederhold es profesor del Departamento de Ciencias de la Computación en la Universidad de Stanford, Standford, CA 94305, Estados Unidos (Fax: + (650) 725-2588; Teléfono: (650) 723-0872, email: wiederhold@cs.stanford.edu).

obtenido eficientemente, para asegurar un resultado valioso. Claramente, se ve que hallar los patrones no lo es todo, sino que hay que entender, actuar, convertir los datos en información, la información en conocimiento y el conocimiento en valor para la organización (Véase Ilustración 3.2.1).



Ilustración 3.2.1: El ciclo de la vida de los datos (Andrés Eyherabide, 2012).⁸

Si bien el concepto de Data Mining es una etapa dentro de un proceso llamado extracción del conocimiento en grandes bases de datos, en este capítulo, se dará a conocer sus técnicas, enfoques, ejemplos y aplicaciones que se han hecho utilizando esta tecnología y las herramientas para el desarrollo de modelos, las que por cierto, realizan la extracción del conocimiento en forma automatizada, con un alto nivel de exactitud de forma rápida y eficaz.

⁸ Charla de Introducción al Data Mining, dada en el Postgrado de Business Intelligence de la Universidad Tecnológica Nacional, Facultad Regional, Buenos Aires, Argentina, martes 23 de Octubre del 2012 (<http://bitly.com/REorwN>).

3.2.2 Data Mining y su relación con los Data Warehouse

Antes de dar a conocer clara y detalladamente lo que significa Data Mining y todo lo que conlleva esta etapa, vamos a aclarar un concepto que se relaciona constantemente, aunque no siempre, con la minería de datos, este es el Data Warehouse.

En principio, un Data Warehouse lo podemos asimilar como un término o concepto muy relacionado con la fase de Data Mining y que en teoría para aplicar mejor las técnicas avanzadas de esta etapa, éstas debiesen estar totalmente incorporadas con el Data Warehouse, así como con herramientas interactivas y flexibles, todo esto nos sirve para cuando tenemos grandes volúmenes de datos o cuando se combinan de formas arbitrarias y no predefinidas.

Es por eso que en esta sección se pretende describir rápidamente lo que es un *Almacén de datos* o *Data Warehouse*, para su posterior comprensión, sin profundizar demasiado ni desenfocarnos del tema principal (Data Mining).

Las bases de datos de una empresa utilizan los computadores como medio para organizar sus datos de forma que sean comprensibles para los usuarios. A este proceso se le denomina como Data Warehousing.

Según Bill Inmon⁹ un Data Warehouse es “*una colección de datos orientados a temas, integrados, no-volátiles y variante en el tiempo, organizados para soportar necesidades empresariales*” [1992].

Estos concentran un gran volumen de información de interés para toda una organización, la cual se distribuye por medio de diversas herramientas de consulta y de creación de informes orientadas a la toma de decisiones, tiene por objetivo agrupar los datos con la finalidad de facilitar su posterior análisis mediante diversas herramientas, entre ellas, la minería de datos.

⁹ Bill Inmon es un Informático destacado, reconocido por muchos como el padre de los Data Warehouse fundador de la Corporate Information Factory (CIF), Castle Rock, CO 80104, Estados Unidos (Fax: (303) 681-0774).

La etapa de Data Mining extrae los conocimientos guardados o información predictiva desde el Data Warehouse sin requerir pedidos o preguntas específicas, a través de sus diferentes técnicas algorítmicas. El almacén de datos ahora pasa a ser un sistema de "información central" en todo este proceso.

Actualmente los Data Warehouse y las técnicas OLAP (On-line Analytical Processing) son las maneras más efectivas y tecnológicamente más avanzadas para integrar, transformar y combinar los datos para facilitar al usuario o a otros sistemas el análisis de la información. Sin embargo la minería de datos es un conjunto de técnicas de análisis de datos, con una característica muy especial, que permite:

- Extraer patrones y tendencias para **describir** y comprender mejor los datos.
- Extraer patrones y tendencias para **predecir** comportamientos futuros.

La gran y principal diferencia entre Data Mining y las demás herramientas que se asocian con Data Warehouse, es que esta etapa no tiene por objetivo transformar y facilitar el acceso a la información para que el usuario después la analice más fácilmente, sino que tiene por propósito analizar los datos obteniendo conocimiento útil para una toma de decisiones de manera adecuada.

Resumiendo, el Data Warehouse proporciona una información de gestión accesible, uniforme, actualizada y correcta. Proporciona un mejor servicio al cliente, un menor coste en la toma de decisiones, una mayor flexibilidad ante el entorno y permite el rediseño de los procesos.

Además, las técnicas de Data Mining son utilizadas habitualmente para el análisis y explotación de los datos de un Data Warehouse, brindando soluciones que están basadas en la implementación, a través de la programación, de interfaces de uso general y algoritmos propios y disponibles para todos, permitiendo una eficiente exploración y organización de los datos.

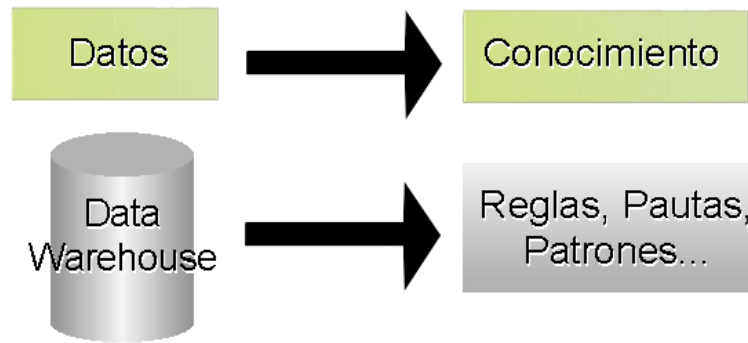


Ilustración 3.2.2: Data Warehouse y su relación con la minería de datos.

3.2.3 Minería de datos y sus necesidades

Los autores Witten¹⁰ y Frank¹¹ definen la minería de datos como *“el proceso de extraer conocimiento útil y comprensible, previamente desconocido, desde grandes cantidades de datos almacenados en distintos formatos” [2000].*

Según Firestone¹² la minería de datos *“es la actividad de extracción de información oculta (patrones y relaciones) de grandes bases de datos, de forma automatizada, es decir, sin intervención humana en el proceso del descubrimiento de conocimiento” [1997].* Desde este punto de vista la minería de datos, no es más que, el descubrimiento de conocimiento automatizado en grandes bases de datos, para una posterior toma de decisiones respecto a un problema determinado. Por ejemplo, qué productos se comercializan mejor en la temporada navideña, en qué regiones es productivo sembrar café, qué áreas de una zona urbana incrementarán su demanda de escuelas primarias, etc.

Actualmente el análisis de los datos en una base de datos se desarrolla mediante consultas realizadas con lenguajes generales de consultas, como el SQL, estas se efectúan sobre las bases de datos operacionales, es decir, junto al procesamiento

¹⁰ Ian H. Witten es profesor del Departamento de Ciencias de la Computación de la Universidad de Waikato, Hamilton, Nueva Zelanda (Fax: 858-5095, Teléfono: +64 7 838-4246, email: ihw@cs.waikato.ac.nz).

¹¹ Eibe Frank es profesor del Departamento de Ciencias de la Computación de la Universidad de Waikato, Hamilton, Nueva Zelanda (Teléfono: +64 7 838-4396, email: eibe@cs.waikato.ac.nz).

¹² Joseph M. Firestone es vicepresidente y director de la oficina de conocimiento del Sistema Ejecutivo de Información (IES), Alexandria, VA 2230, Estados Unidos (Teléfono: (703) 461-8823, email: eisai@home.com).

transaccional en línea (On-line Transaction Processing, OLTP) de las aplicaciones de gestión. Las consultas en este procesamiento permiten extraer información resumida. Sin embargo, esto solo genera información resumida de forma previamente establecida, poco escalable a grandes volúmenes de datos y poco flexible.

Ante las nuevas demandas que surgen debido al crecimiento masivo y la diversidad de fuentes de información, se da un paso más y aparece una nueva arquitectura: el almacén de datos (Data Warehouse). Este almacén consiste en un repositorio de fuentes heterogéneas de datos, integrados y organizados bajo un esquema unificado para favorecer su análisis y dar soporte a la toma de decisiones mejorando los procesos de negocios en cualquier organización. Esta tecnología incluye operaciones de procesamiento analítico en línea (On-line Analytical Processing, OLAP), es decir, técnicas de análisis como pueden ser el resumen, la consolidación o la agregación y también la posibilidad de ver la información desde diferentes enfoques o perspectivas.

A pesar de que las herramientas OLAP soportan ciertos análisis descriptivos y de sumarización que permiten transformar de cierta manera los datos en otros datos agregados o combinados, necesitan la habilidad de generar reglas, patrones, pautas, es decir, conocimiento útil que pueda ser aplicado en otros datos.

Existen otras herramientas analíticas que han sido utilizadas con el fin de analizar los datos y que tienen su origen en la estadística. Aunque estas herramientas son capaces de inferir patrones a partir de los datos (utilizando modelización estadística paramétrica o no paramétrica), el problema que poseen, es que resultan especialmente crípticos para los no estadísticos, es decir, no funcionan bien para bases de datos de grandes volúmenes (con millones de registros, cientos de tablas, con peso de varios gigabytes y una alta dimensionalidad), que son las que se usan actualmente, además no se incorporan bien con los sistema de información y no soportan algunos tipos de datos frecuentes (atributos nominales con muchos valores, multimedia, datos textuales, etc.)

Es así, como las nuevas necesidades parten de que la importancia no radica en los datos como tales, sino en el conocimiento que se puede extraer a partir de ellos y aún más, en que dicho conocimiento sea utilizable. Estas necesidades y las restricciones de la técnicas existentes ayudan al origen de una nueva generación de herramientas que posibiliten la

extracción de conocimiento útil, a través de la información que se disponga, y que contenidas en una denominación, reciben el nombre de “minería de datos” (Data Mining).

La minería de datos se diferencia de las aproximaciones anteriores, en que no obtiene información explícita extensional (datos) sino implícita intencional (conocimiento) y dicho conocimiento no es una estandarización de ningún modelo preestablecido o intuitivo por el usuario, sino que es un modelo novedoso y original, extraído completamente por la herramienta.

La minería de datos constituye la fase central del proceso denominado extracción del conocimiento en bases de datos (KDD) y el resultado que genera esta fase son patrones, conjuntos de reglas, ecuaciones, árboles de decisiones, entre otros conceptos.

3.2.3.1 Objetivos del Data Mining

A continuación se exponen algunos objetivos importantes dentro de este proceso de minería de datos:

- Producir nuevo conocimiento que pueda resultar útil mediante la construcción de un modelo a partir de los datos recopilados para ello. Dicho modelo es una descripción de los patrones o relaciones entre los datos y puede usarse para entender mejor los datos, hacer predicciones o explicar situaciones pasadas.
- Encontrar modelos inteligibles a partir de grandes cantidad de datos que se encuentran en diversos repositorios de datos. Para que este proceso sea efectivo tiene que ser automático o asistido (semi-automático).
 - a) Modelamiento descriptivo: Construcción de modelos que ayudan a entender los datos que se tiene (estimación de distribución de probabilidades, búsqueda de correlaciones entre variables, etc.)
 - b) Modelamiento predictivo: Construcción de un modelo que prediga el valor de una variable determinada.

- A partir de los patrones descubiertos, tomar decisiones más seguras que produzcan algún beneficio a una organización en particular.

3.2.3.2 Ventajas del Data Mining

- Genera Modelos predictivos: Proporciona que relaciones no descubiertas e identificadas mediante la ejecución del proceso del Data Mining sean declaradas como reglas de negocio o modelos predictivos.
- Permite a los usuarios dar prioridad a decisiones y acciones mostrando factores que tienen un mayor en un objetivo, qué segmentos de clientes son desechables y qué unidades de negocio son sobrepasados y por qué.
- Ayuda a la organización, ya que ahorra grandes cantidades de dinero y genera nuevas oportunidades de negocios.
- Admite al usuario examinar toda la base de datos, sin seleccionar previamente un subconjunto de variables.
- Identifica la información clave desde volúmenes de datos generados por procesos tradicionales y extrae los patrones de forma automatizada, esto contribuye de mejor manera la toma de decisiones tácticas y estratégicas.
- Proporciona poderes de decisión a los usuarios del negocio que mejor entienden el problema y el entorno y es capaz de medir las acciones y los resultados de la mejor forma.

3.2.4 El Proceso de Data Mining

En esta parte se emplean distintas fases independientemente de la técnica específica de extracción de conocimiento usada.

Aunque en Data Mining cada caso concreto puede ser radicalmente distinto al anterior, el proceso común a todos ellos se suele componer de cuatro etapas principales:

1. Determinación de los objetivos: Esta fase consiste en la delimitación de los objetivos que el cliente desea bajo la orientación del especialista en Data Mining. Un aspecto muy importante en este paso es que la minería de datos no es un fin en sí mismo, es decir, sin objetivos de negocio no hay proyecto.
2. Pre-procesamiento de los datos: Mediante el pre-procesado, se filtran los datos (se eliminan valores incorrectos, no válidos, desconocidos, etc.), se obtienen muestras de los mismos (mayor velocidad de respuesta del proceso), se enriquecen, se reduce el tamaño de los datos, eligiendo las variables más influyentes en el problema, sin apenas sacrificar la calidad del modelo de conocimiento obtenido del proceso de minería y además ocurre una transformación de las bases de datos. Esta etapa consume generalmente alrededor del 70% del tiempo total de un proyecto de Data Mining.
3. Determinación del modelo: Se comienza realizando unos análisis estadísticos de los datos, y después se lleva a cabo una visualización gráfica de los mismos para tener una primera aproximación. Según los objetivos planteados y la tarea que debe llevarse a cabo, pueden utilizarse algoritmos desarrollados en diferentes áreas de la Inteligencia Artificial.

Mediante la técnica se obtiene un modelo de conocimiento, que representa patrones de comportamiento observados en los valores de las variables del problema o relaciones de asociación entre dichas variables. También pueden usarse varias técnicas a la vez para generar distintos modelos y luego compararlos.

4. Análisis de los resultados: Finalmente se procede a su validación, se verifica si los resultados obtenidos son coherentes y los compara con los obtenidos por los análisis estadísticos y de visualización gráfica. El cliente determina si son novedosos y si le aportan un nuevo conocimiento que le permita considerar sus decisiones.

Cabe destacar, que en el caso de haber obtenido varios modelos mediante el uso de distintas técnicas, se deben comparar los modelos en busca de aquel que se ajuste mejor al problema, viendo su eficacia y validez. Y si ninguno de los modelos alcanza los resultados esperados, se replanteará alguno de los procesos anteriores en busca de nuevos modelos.

3.2.5 Tipos de modelos y enfoques algorítmicos de Data Mining

Según Leo Apostel¹³ un modelo es *“una representación abstracta, gráfica o visual, física, matemática, de fenómenos, sistemas o procesos a fin de analizar, describir, explicar, simular; en general, explorar, controlar y predecir esos fenómenos o procesos”*.

En otras palabras, un modelo nos admite decidir un resultado final, a partir de ciertos datos de entrada en el proceso o sistema.

La minería de datos tiene como objetivo extraer conocimiento útil, a partir del análisis de ciertos datos. Este conocimiento puede ser en forma de patrones o reglas inferidos de los datos, o bien en forma de una descripción más precisa, es decir, un resumen de los mismos, constituyendo un modelo de los datos analizados. Hoy en día, existen muchas formas distintas de interpretar y representar los modelos y cada una de ellas define el tipo de técnica a utilizar para poder inferir dichos modelos.

Existen dos tipos de modelos: los predictivos y descriptivos, los cuales tienen distintas tareas, y a la vez estas tienen sus propios requisitos, que obtienen distintos tipos de información.

En las siguientes hojas de este proyecto, se ha explicado de forma más detallada lo mencionado en el párrafo anterior, explicando los modelos predictivos y descriptivos con sus respectivos enfoques o tareas algorítmicas.

¹³ Leo Apostel (Antwerp, 4 Septiembre 1925 – Ghent, 10 Agosto 1995) fue un Filósofo Belga y profesor de la Universidad de Bruselas, Bélgica.

3.2.5.1 Modelos predictivos

Estiman valores futuros o desconocidos de variables de interés (dependientes), usando otras variables de la base de datos (independientes). En otras palabras, se trata de problemas y tareas en los que hay que predecir uno o más valores para uno o más ejemplos o más bien explicado, intenta predecir o responder a preguntas futuras en base a un estudio de su comportamiento pasado, además estos van acompañados de una salida (clases, categoría o valor numérico). Por ejemplo, un modelo predictivo sería el que permita definir las ventas futuras de un determinado producto.

Entre las tareas predictivas encontramos la clasificación y la regresión.

3.2.5.1.1 Clasificación

Es una tarea muy utilizada, en esta cada registro de la base de datos se relaciona a una clase, la cual se señala mediante el valor de un atributo. Este atributo puede tomar distintos valores discretos correspondientes a una clase determinada, los demás atributos (relevantes), se utilizan para predecir la clase.

El objetivo es predecir la clase de nuevos registros de las que se desconocen la clase, utilizando las reglas generadas, es decir, maximiza la razón de precisión de la clasificación de los nuevos registros que se van agregando, y se calcula de la siguiente manera:

$$\textit{Precisión} = \frac{\textit{Predicciones correctas}}{\textit{Numero total de predicciones (correcta e incorrectas)}}$$

Ecuación 3.2.1: Formula de la clasificación (Hernandez, Ramirez, & Ferri, 2004).

3.2.5.1.2 Regresión

Consiste en aprender una función real que asigna a cada registro un valor real. Esta es la principal diferencia respecto a la clasificación, ya que el valor que se va a predecir es real (tipo numérico).

El objetivo de esta tarea es minimizar el error entre el valor predicho y el valor real, utilizando la función generada. Y dado que la única diferencia con la clasificación es que la regresión predice valores reales, un modelo de regresión podría convertirse fácilmente en un modelo de clasificación.

Se tiene un w_0 y w_1 , donde “ x ” e “ y ” son las dimensiones y “ n ” es el número de ejemplos de la muestra:

$$w_1 = \frac{n(\sum xy) - (\sum x)(\sum y)}{n(\sum x^2) - (\sum x)^2} \quad w_0 = \frac{(\sum y)(\sum x^2) - (\sum x)(\sum xy)}{n(\sum x^2) - (\sum x)^2}$$

Obteniendo la siguiente ecuación:

$$y = w_0 + w_1x$$

Ecuación 3.2.2: Formula de la Regresión Lineal (Mladen W.Nadinic, 2008).

3.2.5.2 Modelos descriptivos

Identifican patrones que explican los datos, es decir, sirven para explorar las propiedades de los datos analizados, proporcionar información entre las relaciones de los datos y sus características y no para predecir nuevos datos. Dado el análisis de los datos se infiere un modelo descriptivo que ayude a la solución de la problemática. El objetivo de este modelo no es predecir nuevos datos, sino que describir los ya existentes.

Por ejemplo, una agencia de viajes y turismo analiza los viajes que han realizados sus clientes e infiere un modelo descriptivo, con el fin de identificar grupos de personas con gustos similares, para poder realizarles distintas ofertas por cada grupo.

Entre las tareas o enfoques descriptivos encontramos el agrupamiento (clustering), las reglas de asociación, y las correlaciones o análisis correlacional.

3.2.5.2.1 Agrupamiento o Clustering

Es uno de los mejores enfoques dentro del modelo descriptivo y consiste en lograr grupos naturales a partir de los datos, esta tarea no analiza datos etiquetados con una clase, sino que los analiza para generar esta etiqueta, debido a esto no se conocen las clases, ya que el objetivo de este enfoque algorítmico es poder describir de forma resumida el conjunto de datos.

Los datos son agrupados basándose en el principio de maximizar la similitud entre los elementos de un grupo y de minimizar la similitud entre los elementos de grupos distintos. En otras palabras, la base de datos se va a segmentar en grupos, donde cada grupo posee objetos que son muy parecidos entre sí, pero que a su vez son muy distintos a los objetos de los otros grupos. Los grupos pueden ser o no disjuntos.

También los resultados obtenidos mediante este enfoque, van a poder ser utilizados como entrada a otros métodos, o para resumir los contenidos de las grandes bases de datos.

3.2.5.2.2 Asociación

Esta tarea busca relaciones no explícitas entre los valores de atributos discretos. El objetivo de la asociación es poder describir de forma precisa relaciones existentes entre los valores de los atributos de un conjunto de datos. Es decir, encontrar en los datos algunas reglas que identifiquen ciertos patrones de comportamiento.

Las reglas de asociación están formadas por el **antecedente** (la primera parte, “si”), ubicado en el lado izquierdo, y el **consecuente** (la segunda parte, “entonces”), ubicado en el lado derecho, y además ofrecen la información en forma de declaraciones del tipo “si-entonces” (“Si A, entonces B”). No siempre la existencia de una asociación entre atributos,

va a implicar la existencia de una relación causa-efecto, o sea, puede no existir una causa para que los datos estén asociados.

Es utilizada, muchas veces, en el análisis de la cesta de compra (Market-Basket Analysis), para identificar productos que son frecuentemente comprados juntos y así obtener valiosas reglas que puedan usarse de mejor manera para ajustar el inventario de un supermercado por ejemplo.

Existe un caso específico de las reglas de asociación, esta son las “reglas de asociación secuenciales” o “patrones secuenciales”. Y básicamente, lo que se busca con este tipo de reglas es determinar de forma concisa patrones secuenciales en los datos. Se diferencian de las reglas de asociaciones normales en que las relaciones existentes entre los datos se basan en el tiempo. Por ejemplo funcionan de la siguiente forma: “Si sucede el evento X en el instante de tiempo t , entonces sucederá el evento Y en el instante de tiempo $t+n$ ”.

3.2.5.2.3 Correlación

Esta tarea se usa para examinar o buscar el grado de similitud de los valores entre dos atributos numéricos. Posee una fórmula estándar para medir la correlación lineal, esta fórmula es llamada “el coeficiente de correlación r ”, el cual es un valor real que se encuentra entre -1 y 1 ($r \in [-1...1]$). Si r es positivo los atributos tienen un comportamiento similar, es decir, los atributos están perfectamente correlacionados (ambos crecen o decrecen al mismo tiempo), si r es negativo, los atributos están perfectamente correlacionados negativamente, esto quiere decir, que cuando un atributo crece el otro decrece, mientras que si r es 0 no hay correlación [5].

Este análisis de correlaciones, es útil cuando se quiere establecer reglas de ítems correlacionados.

3.2.6 Técnicas de Data Mining

Las técnicas de Data Mining son el resultado de un proceso largo de investigación y desarrollo de productos que derivan de la Inteligencia artificial y de la estadística, estas técnicas son algoritmos con un grado de complejidad, y que son aplicadas sobre un conjunto de datos obteniendo ciertos resultados.

Cada tarea o función puede ser llevada a cabo utilizando distintas técnicas, por ejemplo para generar modelos predictivos pueden ser inferidos por técnicas como árboles de decisión y redes neuronales, por nombrar algunas técnicas. El tipo de conocimiento, que se va a extraer va a marcar claramente la técnica de Minería de Datos a realizar (Hernandez, Ramirez, & Ferri, 2004)

Tradicionalmente, las técnicas de minería de datos se aplicaban sobre información contenida en almacenes de datos. De hecho, muchas grandes empresas e instituciones han creado y a la vez alimentan bases de datos especialmente diseñadas para proyectos de minería de datos en las que centralizan información potencialmente útil de todas sus áreas de negocio.

A continuación se ha detallado y explicado, las técnicas más comúnmente usadas por las personas y empresas que se desarrollan en este campo.

3.2.6.1 Redes neuronales artificiales (RNA)

El término “red neuronal” (NN, por Neural Network) se usa para denotar modelos matemáticos de las funciones del cerebro humano, que pretenden expresar las propiedades del procesamiento paralelo masivo y de la representación distribuida existente en el cerebro.

Las redes neuronales artificiales (ANN, por Artificial Neural Network) son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales, también las redes neuronales artificiales simulan el sistema nervioso real en forma abstracta y consisten en un sistema de interconexión de

neuronas que se aportan mutuamente entre sí, con el fin de generar un estímulo de salida.

Las redes neuronales artificiales se desarrollaron basándose en las siguientes reglas:

- El procesamiento de información ocurre en elementos sencillos llamados neuronas.
- Las neuronas o nodos transmiten señales mediante conexiones establecidas.
- Cada conexión, llamado también como enlace de comunicación, tiene un peso asociado.
- Cada neurona aplica una función de activación a la entrada total recibida de las neuronas conectadas, generando un valor de salida que actuará como valor de entrada que se transmitirá al resto de la red.

Algunas características de esta técnica son:

- Son entrenadas para que den solución a los problemas. Esta enseñanza se realiza repitiendo sistemáticamente entradas clásicas, con sus respectivas salidas o respuestas.
- Son usadas para reconocimiento de patrones, clasificaciones de voz e imagen, procesamiento de lenguaje natural, predicción y optimización.
- Generan modelos de tipo predictivos, producen un solo modelo de este mismo, se utilizan para resolver problemas de enfoques de Clasificación y de Regresión, aunque también a veces resuelven problemas de Agrupamiento.
- La exactitud es generalmente alta.

Son una de las técnicas más difícil de comprender pero poseen ventajas muy significativas como su buen funcionamiento predictivo, la tolerancia a fallos, su auto

organización, su flexibilidad, el método de aprendizaje y también pueden ser utilizadas en tiempo real.

3.2.6.1.1 Estructura

Una red neuronal se fundamenta en el procesamiento distribuido a una red de nodos llamados neuronas o unidades de procesamiento, que son la base de una red neuronal y además tienen la capacidad de trabajar en paralelo. Tanto el paralelismo como el procesamiento distribuido son dos propiedades importantes dentro de la minería de datos, ya que permiten que las redes neuronales puedan procesar cantidades de datos muy elevadas.

A continuación se muestra una imagen con el funcionamiento de una neurona artificial:




Ilustración 3.2.3: Funcionamiento general de una neurona artificial (Palmer y Montaña, 1999).

$$y_j = f\left(\sum_{i=1}^N w_{ij} \cdot x_i + \theta_j\right)$$

Ecuación 3.2.3: Representación matemática de una neurona artificial (Palmer y Montaña, 1999).

Para entender de mejor manera la imagen se procede a explicar el funcionamiento de una red neuronal artificial. Estas cuentan con tres funciones:

- a) **Función de entrada:** Tiene por objetivo combinar los patrones de entrada que llegan a la neurona dentro de una entrada global. Los valores de entradas se van a multiplicar por sus correspondientes pesos.
- b) **Función de activación:** Calcula la activación de la unidad en función de la entrada total y la activación previa. Como ya dijimos cada neurona aplica una función de activación a la entrada total que recibe de las otras neuronas que están conectadas, siempre y cuando esta entrada supere un cierto umbral y luego emite una señal hacia las neuronas de la capa siguiente. Si el resultado es menor que el valor del umbral, la neurona permanece *inactiva*, por ende no envía ninguna señal.

Algunas funciones de activaciones típicas, no lineales, son:




Ilustración 3.2.4: Activación Tipo Escalon (Izaurieta y Saavedra).




Ilustración 3.2.5: Activación Tipo Sigmoidea (Izaurieta y Saavedra).

También existen activaciones lineales, cuando ocurre estos se dice que es una “neurona lineal”, en caso contrario es una “neurona no lineal”. Las neuronas lineales se representan por un cuadrado mientras que las neuronas no lineales se representan por un círculo.

- c) Función de salida:** Una vez aplicada la función de activación y esta función está por encima del umbral, es decir, lo supera, envía una señal a la función de salida determinando que valor se transfiere a las neuronas vinculadas. Cabe mencionar, que si la función de activación no supera el umbral determinado, no se va a pasar ninguna salida a las otras neuronas.

Se puede estructurar de diferentes formas:

Redes de propagación hacia adelante (Feedforward)

- a) Redes neuronales mono-capas: Es la red neuronal más sencilla, ya que se tiene una capa de neuronas que proyectan las entradas a una capa de neuronas de salida donde se realizan diversos cálculos. En una red mono-capa, las neuronas de salida pueden ser lineales o no lineales. En este tipo de red, todas las neuronas se encuentran totalmente conectadas y no existen ciclos.

Ejemplos:

- Perceptrón: Fue el primer modelo de red neuronal artificial supervisada creado en 1958 por Frank Rosenblatt¹⁴.

Es capaz de aprender y reconocer patrones sencillos convirtiéndolo en el modelo más simple de las redes neuronales. Esto gracias a que es de tipo supervisada, por lo tanto, la red debe ser entrenada con un conjunto de patrones previamente clasificados de manera que, si se los clasifica de

¹⁴ Frank Rosenblatt (11 Julio 1928 – 11 Julio 1971) Desarrolló en el “Aeronautical Laboratory de la Cornell University” el “Perceptron” (Mark 1) Nueva York, Estados Unidos.

forma incorrecta, por medio de una regla de aprendizaje se pueda corregir el error.

La principal limitante del perceptrón, es que sirve únicamente para problemas linealmente separables y que sean de dos clases, es decir, con un hiper plano se deben separar los elementos "deseados" de los "no deseados". Esto se hace mediante una función discriminante lineal creando una frontera de decisión.

Un perceptrón se puede beneficiar con otros perceptrones u otro tipo de neurona artificial, constituyendo así redes neuronales más complejas.

- Adaline: Es un tipo de red neuronal artificial desarrollada por el profesor Bernie Widrow¹⁵ y un alumno, en la Universidad de Stanford en el año 1960. Se utiliza para entrenar un Elemento Simple de Procesado con una función de transferencia lineal.

Se le denomina también como "Regla del Mínimo Error Cuadrático Medio" y la idea es modificar los pesos para tratar de reducir la diferencia entre la salida deseada y la salida actual para cada patrón. Cabe destacar, que se calcula una función de error para todo el conjunto de patrones.

Se compone de una sola capa de " n " nodos o neuronas generando así " n " salidas, con " m " entradas.

La estructura de esta red es muy similar a la del perceptrón simple, resuelve problemas linealmente separables, pero es un mecanismo físico capaz de realizar aprendizaje, diferenciándolo del perceptrón en la forma de utilizar la salida en la regla de aprendizaje.

¹⁵ Bernard Widrow, es un profesor del Departamento de Ingeniería Eléctrica de la Universidad de Stanford, Stanford, CA 94305-9510, Estados Unidos (email: smyth@ics.uci.edu).




Ilustración 3.2.6: Red Monocapa (Izaurieta y Saavedra).

- b) Redes neuronales multicapas: Es una extensión de la red neuronal unicapa o monocapa, encontrándose un conjunto de capas intermedias entre la entrada y la salida (capas ocultas). Este tipo de red puede estar total o parcialmente conectada y no existen ciclos.

Ejemplos:

- Perceptrón Multicapa: Es una red neuronal en forma de cascada que tiene una o más capas ocultas, permitiéndole resolver problemas que no son linealmente separables, resolviendo así la gran limitante del perceptrón simple.

Su arquitectura se clasifica en tres capas; la “capa de entrada”, que está constituida por neuronas que introducen los patrones de entrada en la red y propagan la activación a través de los pesos hasta la “capa oculta”, en esta otra capa se aplica alguna función de activación a las entradas que le llegan. Entonces la activación se transmite a través de los pesos hacia la

capa de salida, los valores de las neuronas de la capa de salida corresponden con las salidas de toda la red.

Posee una limitante, esta es la existencia de mínimos locales en la función de error, dificultando de forma considerable el entrenamiento a la red, debido a que una vez que se haya alcanzado un mínimo, el entrenamiento se detiene aunque no se haya alcanzado la tasa de convergencia fijada.

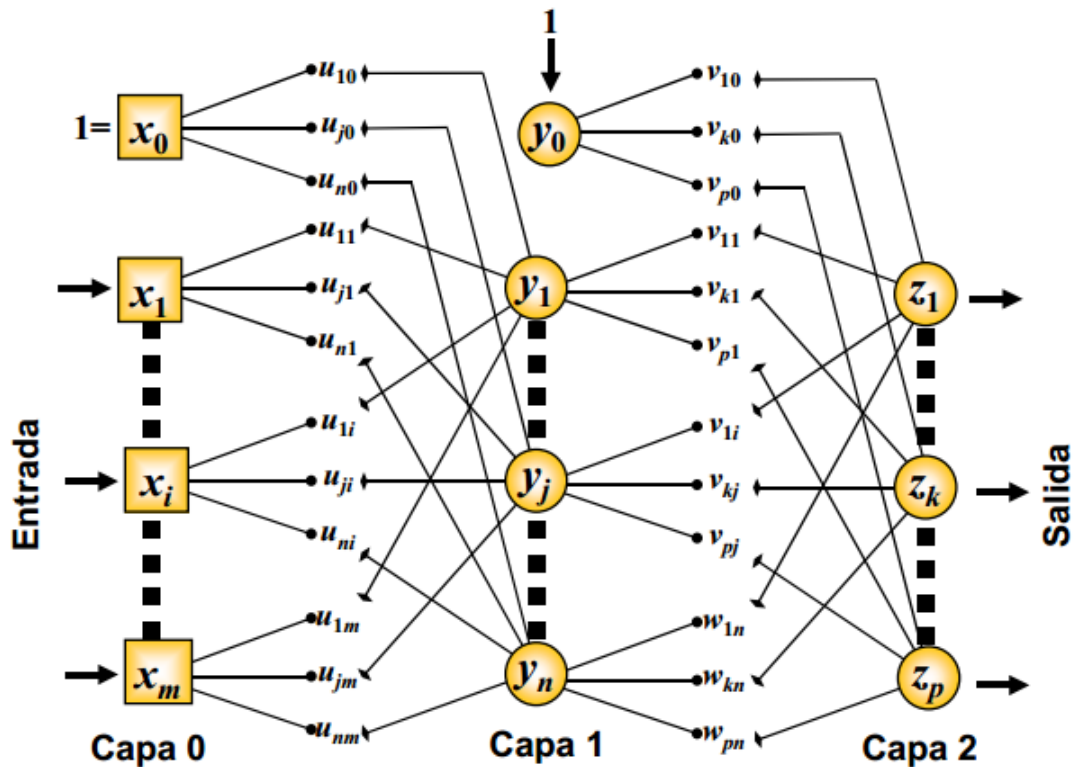


Ilustración 3.2.7: Red Multicapa (Izaurieta y Saavedra).

Redes recurrentes (Feedback)

- a) Redes neuronales recurrentes: Esta red viene caracterizada por la existencia de lazos de realimentación, presenta al menos un ciclo cerrado de activación neuronal. Estos lazos pueden ser entre neuronas de diferentes capas, neuronas de la misma capa o, más sencillamente, entre una misma neurona. Esta estructura estudia principalmente la dinámica de sistemas no lineales.

Ejemplos:

- Redes de Hopfield: Pertenece al grupo de las redes recursivas o recurrentes, es decir, existe una realimentación entre las neuronas. De esta forma, al introducir un patrón de entrada, la información se propaga hacia adelante y hacia atrás, produciéndose una dinámica. Cuando la evolución esté en algún estado estable, esta se detendrá, o también puede ser el caso que la red no se detenga nunca.

Están diseñadas para converger a un mínimo local, pero la convergencia a uno de los patrones almacenados no está garantizada.

Las redes recurrentes deben cumplir tres objetivos:

1. Dado cualquier estado inicial, deben converger siempre a un estado estable.
2. El dominio de atracción de cada estado estable debe estar perfectamente delimitado y cumplir algún criterio de métrica (por ejemplo, que el estado final sea el más cercano al inicial).
3. Debe poder tener cualquier número de estados estables.

La estructura de estas redes es de tipo binaria, es decir, sólo tienen dos valores posibles para sus estados. Y los valores posibles pueden ser 1 ó -1, o bien 1 ó 0.

Suelen usar como memoria auto-asociativa, esto significa que si entra un patrón "x" incompleto o ya sea que este perturbado por el ruido, la red evoluciona hacia el patrón completo más cercano. Esto se produce al entrenamiento que se les enseña, el cual consiste en reducir la energía de los estados que la red debe recordar.

- Máquina de Boltzmann: Es un tipo de red neuronal recurrente estocástica y consisten en neuronas conectadas entre sí que pueden estar conectadas bidireccionalmente y que poseen salidas binarias. Útiles para el reconocimiento de patrones, intentando recuperar información no disponible de un estado. Además, pueden tener unidades ocultas.

Se clasifican en dos grupos: las visibles, que son las que conforman la interfaz de la red y las no visibles, que son las que ayudan a mejorar el desempeño de esta.

Una máquina de Boltzmann se puede ver como una red de varias unidades de dos estados (binaria) conectadas de cierta forma, donde el estado prendido = 1 y apagado = 0.

3.2.6.1.2 Topología

La organización más popular de una red neuronal se constituye de tres capas:

- Capa de entrada
- Capa Oculta
- Capa de Salida

La “*capa de entrada*”, es donde cada neurona o nodo corresponde a una variable independiente a examinar, luego unos nodos internos organizados en una o varias “*capas ocultas*”, realizan el trabajo de la red y dependen de la dificultad del problema, y una “*capa de salida*” con los nodos de salida, este nodo corresponde a la variable dependiente. Generalmente es un nodo el que se encuentra en la capa de salida, aunque si hay más de uno, significa que puede realizarse muchas predicciones.

3.2.6.1.3 Mecanismos de aprendizaje

El aprendizaje ofrece una poderosa alternativa a la programación. Se han propuesto diferentes estrategias de aprendizaje para redes neuronales tales como el aprendizaje supervisado y no-supervisado (Rojas, 1996).

El aprendizaje de una red neuronal más que nada significa: adaptación de los pesos, es decir, es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada.

Dentro de las redes neuronales artificiales existen diversos métodos de aprendizaje siendo dos los más importantes:

- a) Aprendizaje supervisado: Este se caracteriza porque el proceso se realiza mediante un entrenamiento que es controlado por un agente externo, este va a determinar la respuesta que debería producir la red a partir de una entrada determinada. Es el supervisor o maestro quien controla la salida de la red, en caso de que hallan diferencias y no coincida con la esperada, se procede a modificar los pesos de las conexiones, ajustando la red y aumentando la posibilidad de que la nueva salida se aproxime a la deseada.

Existen tres tipos básicos de aprendizajes supervisados:

- Aprendizaje por corrección de error.
- Aprendizaje por refuerzo.
- Aprendizaje estocástico.

Ejemplos:

- Red Backpropagation: Es una red de tipo supervisada, se puede aplicar en modelos de redes con más de dos capas de neuronas. Consiste en un aprendizaje de un conjunto predefinido de pares de entradas y salidas dados previamente, empleando un ciclo de propagación - adaptación de dos fases.

En principio, se aplica un patrón de entrada a la red como estímulo para la primera capa de las neuronas de la red, después se va propagando desde la primera capa a través de las capas superiores de la red, hasta generar una salida. Se compara el resultado obtenido en las neuronas de salida con

la salida que se desea obtener y se calcula una señal de error para cada neurona de salida.

Luego estas señales de error se propagan hacia atrás partiendo de la capa de salida, hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida recibiendo el porcentaje de error aproximado a la participación de la neurona intermedia en la salida original. Este proceso se va repitiendo capa por capa hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total.

Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que en la siguiente vez que se presente el mismo patrón, la salida esté más cercana a la deseada, disminuyendo así el error.

A diferencia de la regla delta en el caso del Perceptrón, esta técnica requiere el uso de neuronas cuya función de activación sea continua y por tanto diferenciable. Generalmente la función será de tipo "Sigmoidal".

- Memoria asociativa bidireccional: Es una red recurrente que implanta una memoria asociativa, se emplea para recordar información al presentarse una cierta información clave. Si la información solo se conoce parcialmente por anticipado, o si tiene ruido, la red es capaz de completar dicha información.

Su arquitectura consta de dos capas de neuronas que están completamente interconectadas entre capas, las cuales pueden ser de diferentes dimensiones. Las unidades pueden o no tener conexiones de retroalimentación consigo mismas.

En esta red ninguna capa puede ser considerada esencialmente solo de salida o de entrada.

A las capas se les denomina “capa-X” y “capa-Y”, respectivamente. Las conexiones de estas capas son bidireccionales, esto quiere decir, que las funciones de la red, de forma iterativa, envían señales hacia atrás y adelante entre las capas hasta que el equilibrio se ha alcanzado.

Posee la limitante de la existencia de los mínimos locales y la capacidad de memoria que posee la red.

- b) Aprendizaje no supervisado: Este aprendizaje no requiere de un agente externo para ajustar la red. Tampoco recibe alguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta. De esta manera lo único que puede hacer la red es reconocer patrones en los datos de entrada y crear categorías a partir de estos patrones. Así después del entrenamiento cuando entre algún dato, la red será capaz de clasificarlo e indicar en que categoría clasificó dicho dato

Existen dos tipos básicos de aprendizajes supervisados:

- Aprendizaje hebbiano.
- Aprendizaje competitivo y comparativo.

Ejemplos:

- Mapas de Kohonen: Las redes auto-organizadas fueron inventadas por Teuvo Kohonen¹⁶, entre los años 1982 y 1990, Kohonen creó una manera de representar datos de un espacio multidimensional en otro espacio de menores dimensiones.

Las redes de Kohonen están compuestas de dos capas: la capa de entrada de sensores y la capa de salida que realiza el cálculo.

¹⁶ Teuvo Kohonen, es un profesor de la Academia de Finlandia. Su más famosa contribución es: los mapas auto-organizados.

Las neuronas que representan los patrones parecidos aparecen juntas en el espacio salida. Este espacio salida es establecido por el diseñador de la red.

Las neuronas están distribuidas a lo largo de todo el espacio de entrada. De esta forma, al introducirse un ejemplo, se activa sólo la neurona que más cerca esté de dicho ejemplo en el espacio de entrada.

La idea se basa en un funcionamiento biológico de aprendizaje por competición, de forma que cuando un conjunto de datos de entrada se presenta a la red, los pesos de las neuronas se adaptan de forma que la clasificación presente en el espacio de entrada sea preservada en la salida.

- Máquina de Cauchy: Es una versión mejorada de la máquina de Boltzmann, posee la misma arquitectura y funcionamiento, pero se diferencia ya que considera funciones alternativas de probabilidad y de ajuste de temperatura.

Posee una gran ventaja respecto a la máquina de Boltzmann, esta radica en la rapidez de convergencia. También, se ha demostrado que combinando las funciones de probabilidad y temperatura previa se consigue alcanzar siempre el mínimo global de energía.

- Resonancia Adaptativa: Fue desarrollada por Stephen Grossberg¹⁷ y Gail Carpenter¹⁸ para tratar de resolver la “Teoría de Resonancia Adaptativa”, el cual trata conseguir un modelo que sea capaz de dar respuesta a problemas de como una red puede aprender nuevos patrones (plasticidad del aprendizaje) y como una red puede retener los patrones previamente aprendidos (estabilidad del aprendizaje).

¹⁷ Stephen Grossberg, es un profesor de Matemáticas, Psicología e Ingeniería Biomédica y Director del Centro de Sistemas de adaptación de la Universidad de Boston, Boston, MA 02215, Estados Unidos (Teléfono: (617) 353-7857, email: steve@bu.edu).

¹⁸ Gail Carpenter, es una profesora de Matemáticas y directora del Departamento de sistemas cognitivos y neurales (SNC) Tecnología de laboratorio en la Universidad de Boston, Boston, MA 02215, Estados Unidos (Teléfono: (617) 353-9483, email: gail@cns.bu.edu).

El modelo propone un sistema competitivo en el que ante una determinada información de entrada, solo una de las neuronas de salida de la red se activa, alcanzando su valor de respuesta máximo tras competir con las neuronas restantes. Para solucionar esto, las redes de resonancia adaptativa proponen añadir un mecanismo de retroalimentación entre las neuronas de la capa de salida y la capa de entrada, con el objetivo de facilitar el aprendizaje de nueva información, pero sin destruir la que ya está almacenada.

Hay dos métodos básicos de entrenar una red de resonancia adaptativa: lento y rápido. Con el primer método el grado de entrenamiento de los pesos de la neurona de reconocimiento hacia el vector de entrada se calcula a valores continuos con ecuaciones diferenciales. En cambio, con el método rápido, se utilizan ecuaciones algebraicas para calcular el grado de ajustes de peso, usándose valores binarios.

A medida que la red va aprendiendo, ésta va creando su propia clasificación, el aprendizaje es de tipo no supervisado, aunque existe una modalidad supervisada.

Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren distintas modificaciones, por lo tanto, se puede afirmar que este proceso ha terminado o que la red ha aprendido, cuando los valores de los pesos permanecen estables.

Un aspecto no menor respecto al aprendizaje de las redes neuronales es saber cómo es que se ajusta la red cuando una salida no es como la deseada, o sea, cuáles son los criterios que se utilizan para cambiar los valores de los pesos.

En fin, hay una amplia selección de modelos de redes neuronales artificiales. La combinación de la topología (el número de neuronas y capas ocultas, y cómo están conectadas), el paradigma de aprendizaje y el algoritmo de aprendizaje definen un modelo de red neuronal artificial (Bigus, 1996).

3.2.6.2 Árboles de decisión (AD)

Un árbol de decisión es un conjunto de condiciones organizadas en una estructura jerárquica, el cual contiene cero o más nodos internos y uno o más nodos de hoja. Los nodos internos tienen dos o más nodos secundarios y contienen divisiones, los cuales prueban el valor de una expresión de los atributos. Los arcos de un nodo interno a otro secundario (o de menor jerarquía) son etiquetados con distintas salidas de la prueba del nodo interno. Cada nodo hoja tiene una etiqueta de clase asociada.

El Árbol de Decisión también es un modelo de predicción que permite categorizar y representar de forma gráfica una serie de reglas que ocurren de forma sucesiva, sobre la decisión que se debe tomar en la asignación de un valor de salida a un determinado registro, resolviendo un determinado problema.

La construcción de un Árbol de Decisión se basa en el principio de “divide y vencerás”: a través de un algoritmo de aprendizaje supervisado se realizan divisiones sucesivas del espacio multivariable para maximizar la distancia entre grupos en cada división, es decir, realiza particiones que discriminan [Palmer y otros, 2008].

3.2.6.3 Naïve Bayes (NB)

Esta es una de las técnicas más utilizadas y está basada en condiciones probabilísticas, hace uso del Teorema de Bayes propuesto en 1764 por Thomas Bayes¹⁹, y mediante esto realiza las predicciones. Puede predecir la probabilidad de que un caso dado pertenezca a una clase determinada y es usada principalmente para resolver problemas de clasificación aunque también genera un modelo predictivo y descriptivo

El adjetivo “*Naïve*” (ingenuo), es considerado de tal forma, ya que supone que el efecto de un valor de atributo sobre una clase dada es independiente de los valores de los otros atributos (Han y Kamber, 2006).

¹⁹ Thomas Bayes (Londres, Inglaterra, ~1702 - Tunbridge Wells, 1761) fue un matemático británico. Su obra más conocida es el Teorema de Bayes.

Si los atributos son condicionalmente independientes dada la clase, este clasificador va a superar a los clasificadores de redes neuronales artificiales, como también a los árboles de decisión.

3.2.7 Algunas aplicaciones de Data Mining

Cada año, en los diferentes congresos, conferencias y talleres que se realizan alrededor de todo el mundo se congregan muchos investigadores con aplicaciones muy diversas. Ya que la minería de datos se ha ido integrando a la vida de empresas, hospitales, universidades, gobiernos y varias organizaciones que están interesadas en explorar sus bases de datos, por ende, es un buen momento para ver el alcance y avance de esta tecnología. Podemos decir que "en data mining cada caso es un caso". (Molina, 2002)

A continuación se detallan diferentes ejemplos donde se ha visto involucrado la minería de datos. Se han elegido de diversos dominios y con distintos objetivos para observar realmente su potencial. En relación a los modelos inteligentes, se ha comprobado que en ellos se utilizan principalmente árboles y reglas de decisión, reglas de asociación, redes neuronales, redes bayesianas, conjuntos aproximados, algoritmos de agrupación (clustering), máquinas de soporte vectorial, algoritmos genéticos y lógica difusa.

3.2.7.1 En el gobierno.

El FBI ha analizado las bases de datos comerciales para detectar terroristas.

A principios del mes de julio de 2002, el director del Federal Bureau of Investigation (FBI), John Aschcroft, anunció que el Departamento de Justicia comenzará a introducirse en la vasta cantidad de datos comerciales referentes a los hábitos y preferencias de compra de los consumidores, con el fin de descubrir potenciales terroristas antes de que ejecuten una acción. Algunos expertos aseguran que, con esta información, el FBI unirá todas las bases de datos probablemente mediante el número de la Seguridad Social y permitirá saber si una persona fuma, qué talla y tipo de ropa usa, su registro de arrestos, su salario, las revistas a las que está suscrito, su altura y peso, sus contribuciones a la Iglesia, grupos políticos u organizaciones no gubernamentales, sus enfermedades crónicas (como diabetes o asma), los libros que lee, los productos de supermercado que compra, si tomó

clases de vuelo o si tiene cuentas de banco abiertas, entre otros. La inversión inicial ronda los setenta millones de dólares estadounidenses para consolidar los almacenes de datos, desarrollar redes de seguridad para compartir información e implementar nuevo software analítico y de visualización. [1]

Básicamente, lo que pretende el FBI es vigilar a ciertos clientes de comercios alrededor de todo el mundo para detectar, por medio de Data Mining, cuáles de ellos tienen el perfil de terroristas y así anticipadamente tomar las medidas de seguridad correspondientes.

3.2.7.2 En los clubes deportivos

El AC de Milán utiliza un sistema inteligente para prevenir lesiones.

Esta temporada el club de fútbol italiano comenzará a usar redes neuronales para prevenir lesiones y optimizar el acondicionamiento de cada atleta. Esto ayudará a seleccionar el fichaje de un posible jugador o a alertar al médico del equipo de una posible lesión. El sistema, creado por Computer Associates International, es alimentado por datos de cada jugador, relacionados con su rendimiento, alimentación y respuesta a estímulos externos, que se obtienen y analizan cada quince días. El jugador lleva a cabo determinadas actividades que son monitoreadas por veinticuatro sensores conectados al cuerpo y que transmiten señales de radio que posteriormente son almacenadas en una base de datos. Actualmente el sistema dispone de 5.000 casos registrados que permiten predecir alguna posible lesión. Con ello, el club intenta ahorrar dinero evitando comprar jugadores que presenten una alta probabilidad de lesión, lo que haría incluso renegociar su contrato. Por otra parte, el sistema pretende encontrar las diferencias entre las lesiones de atletas de ambos sexos, así como saber si una determinada lesión se relaciona con el estilo de juego de un país concreto donde se practica el fútbol. [1]

3.2.7.3 En investigaciones espaciales

Proyecto SKYCAT.

Durante seis años, el Second Palomar Observatory Sky Survey (POSS-II) coleccionó tres terabytes de imágenes que contenían aproximadamente dos millones de objetos en el cielo. Tres mil fotografías fueron digitalizadas a una resolución de 16 bits por píxel con

23.040 x 23.040 píxeles por imagen. El objetivo era formar un catálogo de todos esos objetos. El sistema Sky Image Cataloguing and Analysis Tool (SKYCAT) se basa en técnicas de agrupación (*clustering*) y árboles de decisión para poder clasificar los objetos en estrellas, planetas, sistemas, galaxias, etc. con una alta confiabilidad [Fayyad y otros, 1996]. Los resultados han ayudado a los astrónomos a descubrir dieciséis nuevas fuentes astronómicas de energía electromagnética (cuásars) con corrimiento hacia el rojo que los incluye entre los objetos más lejanos del universo y, por consiguiente, más antiguos. Estos cuásars son difíciles de encontrar y permiten saber más acerca de los orígenes del universo. [1]

3.2.7.4 En la universidad

Conociendo si los recién titulados de una universidad llevan a cabo actividades profesionales relacionadas con sus estudios.

Se hizo un estudio sobre los recién titulados de la carrera de Ingeniería en Sistemas Computacionales del Instituto Tecnológico de Chihuahua II, en México (Rodas, 2001). Se quería observar si sus recién titulados se insertaban en actividades profesionales relacionadas con sus estudios y, en caso negativo, se buscaba saber el perfil que caracterizó a los ex-alumnos durante su estancia en la universidad. El objetivo era saber si con los planes de estudio de la universidad y el aprovechamiento del alumno se hacía una buena inserción laboral o si existían otras variables que participaban en el proceso. Dentro de la información considerada estaba el sexo, la edad, la escuela de procedencia, el desempeño académico, la zona económica donde tenía su vivienda y la actividad profesional, entre otras variables. Mediante la aplicación de conjuntos aproximados se descubrió que existían cuatro variables que determinaban la adecuada inserción laboral, que son citadas de acuerdo con su importancia: zona económica donde habitaba el estudiante, colegio de dónde provenía, nota al ingresar y promedio final al salir de la carrera. A partir de estos resultados, la universidad tendrá que hacer un estudio socioeconómico sobre grupos de alumnos que pertenecían a las clases económicas bajas para dar posibles soluciones, debido a que tres de las cuatro variables no dependían de la universidad. [1]

3.2.7.5 En la empresa

Descubriendo el porqué de la deserción de clientes de una compañía operadora de telefonía móvil.

Este estudio fue desarrollado en una operadora española que básicamente situó sus objetivos en dos puntos: el análisis del perfil de los clientes que se dan de baja y la predicción del comportamiento de sus nuevos clientes. Se analizaron los diferentes históricos de clientes que habían abandonado la operadora (12,6%) y de clientes que continuaban con su servicio (87,4%). También se analizaron las variables personales de cada cliente (estado civil, edad, sexo, nacionalidad, etc.). De igual forma se estudiaron, para cada cliente, la morosidad, la frecuencia y el horario de uso del servicio, los descuentos y el porcentaje de llamadas locales, interprovinciales, internacionales y gratuitas. Al contrario de lo que se podría pensar, los clientes que abandonaban la operadora generaban ganancias para la empresa; sin embargo, una de las conclusiones más importantes radicó en el hecho de que los clientes que se daban de baja recibían pocas promociones y registraban un mayor número de incidencias respecto a la media. De esta forma se recomendó a la operadora hacer un estudio sobre sus ofertas y analizar profundamente las incidencias recibidas por esos clientes. Al descubrir el perfil que presentaban, la operadora tuvo que diseñar un trato más personalizado para sus clientes actuales con esas características. Para poder predecir el comportamiento de sus nuevos clientes se diseñó un sistema de predicción basado en la cantidad de datos que se podía obtener de los nuevos clientes comparados con el comportamiento de clientes anteriores.

[1]

3.2.8 Herramientas de Data Mining

3.2.8.1 Introducción

Las herramientas de Data Mining predicen futuras tendencias y comportamientos, mediante la exploración de las bases de datos en busca de patrones ocultos, permitiendo en los negocios tomar decisiones proactivas y conducidas por un conocimiento acabado de la información.

También pueden responder preguntas que generalmente demandan demasiado tiempo, encontrando información que ni un profesional experto podría hallar porque se encuentra fuera de sus expectativas.

Cabe aclarar, que algunas herramientas de Data Mining permiten integrar datos históricos con entradas de datos en tiempo real, dando como resultado la posibilidad de ejecutar Data Mining en tiempo real.

Para el desarrollo de modelos de minería de datos existen muchas herramientas de software, ya sean libres o comerciales.

Según una encuesta hecha en el portal del reconocido sitio "*kdnuggets*"²⁰, relacionado con la minería de datos y el proceso de extracción de conocimiento en bases de datos, dieron a conocer las herramientas más utilizadas en esta tecnología en los últimos 12 meses (Tomando en cuenta desde el año 2012 hacia atrás).

²⁰ <http://www.kdnuggets.com> es una página de Análisis y minería de datos, con muchas Noticias, Trabajos, Consultoría, Software, Datos, Cursos, Educación, y más. Administrada y editada por Gregory Piatetsky-Shapiro, Brookline, MA 02446, Estados Unidos.

Legend: Free/Open Source tools	% users in 2012
Commercial tools	% users in 2011
R (245)	30.7% 23.3%
Excel (238)	29.8% 21.8%
Rapid-I RapidMiner (213)	26.7% 27.7%
KNIME (174)	21.8% 12.1%
Weka / Pentaho (118)	14.8% 11.8%
StatSoft Statistica (112)	14.0% 8.5%
SAS (101)	12.7% 13.6%
Rapid-I RapidAnalytics (83)	10.4% not asked in 2011
MATLAB (80)	10.0% 7.2%
IBM SPSS Statistics (62)	7.8% 7.2%
IBM SPSS Modeler (54)	6.8% 8.3%
SAS Enterprise Miner (46)	5.8% 7.1%
Orange (42)	5.3% 1.3%
Microsoft SQL Server (40)	5.0% 4.9%
Other free analytics/data mining software (39)	4.9% 4.1%
TIBCO Spotfire / S+ / Miner (37)	4.6% 1.7%

Oracle Data Miner (35)	4.4% 0.7%
Tableau (35)	4.4% 2.6%
JMP (32)	4.0% 5.7%
Other commercial analytics/data mining software (32)	4.0% 3.2%
Mathematica (23)	2.9% 1.6%
Miner3D (19)	2.4% 1.3%
IBM Cognos (16)	2.0% not asked in 2011
Stata (15)	1.9% 0.8%
Bayesia (14)	1.8% 0.8%
KXEN (14)	1.8% 1.4%
Zementis (14)	1.8% 3.7%
C4.5/C5.0/See5 (13)	1.6% 1.9%
Revolution Computing (11)	1.4% 1.4%
Salford SPM/CART/MARS/TreeNet/RF (9)	1.1% 10.6%
Angoss (7)	0.9% 0.8%
SAP (including BusinessObjects/Sybase/Hana) (7)	0.9% not asked in 2011
XLSTAT (7)	0.9% 0.9%
RapidInsight/Veera (5)	0.6% not asked in 2011
11 Ants Analytics (4)	0.5% 5.6%
Teradata Miner (4)	0.5% not asked in 2011
Predixion Software (3)	0.4% 0.5%
WordStat (3)	0.4% 0.5%

Ilustración 3.2.8: Encuesta de las herramientas utilizadas frecuentemente (Junio 2012)²¹.

²¹ <http://www.kdnuggets.com/polls/2012/analytics-data-mining-big-data-software.html>

En rojo están marcadas las herramientas libres y en color verde las herramientas de tipo comercial, mientras que la barra de color morado indica en términos porcentuales la cantidad de personas que utilizaron dichas herramientas en el año 2012, y la barra de color naranja representa el porcentaje de las personas que utilizaron esas herramientas en el año 2011.

Esta encuesta en su versión 13°, fue realizada a un total de 798 participantes que han utilizado, no solo evaluado, herramientas de minería de datos. Y por primera vez, el número de usuarios de software libre / código abierto supera el número de usuarios de software comercial.

De todas estas herramientas, se han seleccionado dos para compararlas entre sí y ver cuál es más efectiva, fácil de usar y mejor en comparación a la otra. Una de ellas es “WEKA” que según la encuesta mostrada anteriormente, es una gran herramienta gratuita para trabajar el proceso de minería de datos. La otra seleccionada es “KEEL”, una herramienta la cual no aparece en la encuesta anterior, pero que también es un software libre y muy recomendado por su fácil uso. Es esto último (Licencia GNU-GPL) lo que influye fuertemente en la elección de ambas herramientas y no de otras de tipo comercial, como por ejemplo: “SPSS CLementine” o “SAS”.

3.2.8.2 WEKA (Waikato Environment for Knowledge Analysis)

La herramienta WEKA es una plataforma de software para aprendizaje automático y minería de datos escrito en Java y desarrollado en la Universidad de Waikato (Nueva Zelanda). WEKA es un software libre distribuido bajo licencia GNU-GPL.

En 1993 se da inicio al desarrollo de la versión original de WEKA, en los lenguajes de C y TCL/TK, ya en 1997 se decidió reescribir el código en Java utilizándose en muchas y muy diferentes áreas, en general con fines docentes y de investigación.

La WEKA (*Gallirallus australis*) es un ave no voladora con una naturaleza inquisitiva y se encuentra en las islas de Nueva Zelanda, da nombre también a una extensa colección de algoritmos máquinas de conocimiento desarrollados por la universidad de Waikato (Nueva

Zelanda) implementados en Java [3]. Los algoritmos bien se pueden aplicar directamente a un conjunto de datos o llamadas desde su propio código Java.



Ilustración 3.2.9: Ave WEKA.

Esta herramienta está orientada a la extensibilidad por lo que agregar nuevas funcionalidades es una tarea sencilla.

3.2.8.2.1 Funcionamiento de WEKA

Está constituido por una colección de paquetes y herramientas de visualización y algoritmos para análisis de datos y modelado predictivo, unidos a una interfaz gráfica de usuario para acceder fácilmente a sus funcionalidades. Estos paquetes pueden ser integrados en cualquier proyecto de análisis de datos, e incluso pueden extenderse con contribuciones de los usuarios que desarrollen nuevos algoritmos.

La herramienta tiene 4 interfaces de usuario para interactuar con ella y así acceder a sus funcionalidades, estas son: Simple CLI, Explorer, Experimenter, Knowledge Flow.

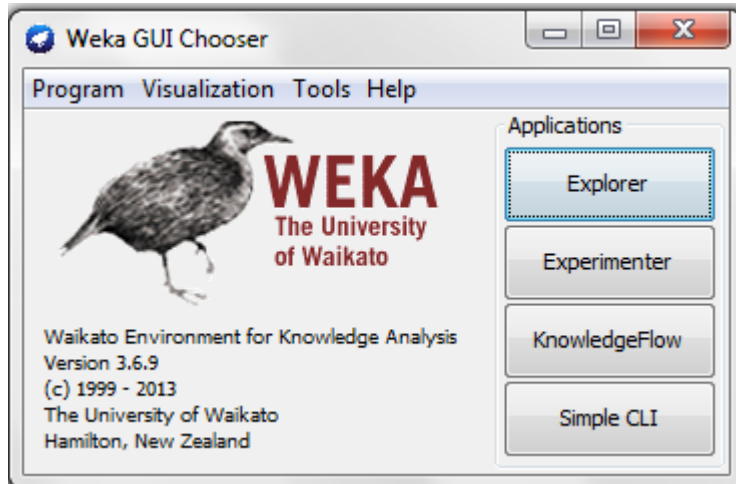


Ilustración 3.2.10: Inicio del software WEKA.

- a) Simple CLI: es una abreviación de Simple Command-Line Interface (Interfaz Simple de Línea de Comandos). Esta interfaz proporciona una consola para poder introducir órdenes desde la línea de comandos, permitiendo ejecutar cualquier operación soportada por WEKA de forma directa. Ya prácticamente no se usa debido a que se fue recubriendo WEKA con otras interfaces más fáciles de utilizar para el usuario común.

- b) Explorer: Es el modo descriptivo más usado, dispone de varios paneles y permite realizar operaciones sobre un solo archivo de datos.

El Explorer permite ejecutar distintas tareas, las cuales están insertadas en varios paneles, la cuales son: Pre-procesado de los datos (Algoritmos de filtrados son utilizados para transformar los datos y eliminar registros), Clasificación (Algoritmos de clasificación son aplicados para estimar la exactitud del modelo predictivo resultante), Clustering (Da acceso a las técnicas de agrupamiento para aprender una mezcla de distribuciones normales), Asociaciones (Las reglas de asociación intentan identificar las interrelaciones importantes entre los atributos de los datos), Selección de atributos (Proporciona algoritmos para identificar los atributos más predictivos en un conjunto de datos) y Visualización de datos (Muestra una matriz de puntos dispersos, donde cada punto puede ser analizado en detalle).

- c) Experimenter: Es un modo útil para aplicar varios algoritmos de aprendizaje automático sobre distintos conjuntos, y luego poder realizar contrastes estadísticos entre ellos y obtener otros índices estadísticos, es decir, el Experimenter nos dirá si las diferencias aparentes en porcentajes de aciertos de distintos algoritmos son estadísticamente significativas, o son debidas al azar.
- d) Knowledge Flow: Es la interfaz más cuidada del programa. Su funcionamiento es grafico posee casi las mismas funciones que el Explorer pero con una interfaz que permite “arrastrar y soltar” facilitando con creces su uso y una ventaja notoria es que ofrece soporte para el aprendizaje incremental.

3.2.8.2.2 Beneficios y problemas

Como toda herramienta, WEKA tiene sus pro y su contra, pero que sin duda marcan una dominación las ventajas y razones que favorecen el uso de este software, más que sus carencias.

a) Beneficios:

- Software de libre distribución bajo la licencia publica general de GNU.
- Corre en casi cualquier plataforma.
- Portabilidad.
- Contiene una gran colección de técnicas para el pre-procesamiento de datos.
- Fácil uso para principiantes, debido a uso interfaz gráfica de usuario.
- Entrega de resultados sencillos de interpretar.

b) Problemas:

- Escasa documentación orientada al usuario.
- Los algoritmos de WEKA no cubren el área de modelado de secuencias.

3.2.8.3 KEEL (Knowledge Extraction based on Evolutionary Learning)

La herramienta KEEL es una herramienta de software para evaluar algoritmos evolutivos para una amplia gama de problemas de Data Mining. Desarrollada en la Universidad de Granada (España), es un software no comercial y distribuido bajo la licencia GNU-GPL, aunque entre los años 2004 y 2010 estuvo bajo derechos de autor (copyright). Asimismo puede ser utilizado en cualquier maquina con Java ya que está desarrollado mediante esta plataforma.

Esta herramienta administra una abundante librería de sistemas difusos evolutivos y también dispone de módulos de tratamiento de datos y análisis estadísticos, cabe destacar, que es la primera herramienta de software de este tipo que contiene una biblioteca de algoritmos de aprendizaje evolutivo con código libre en Java.

3.2.8.3.1 Funcionamiento de KEEL

KEEL facilita el análisis del comportamiento de aprendizaje evolutivo en las diferentes áreas de tareas de aprendizaje y de pre-procesamiento, por lo que la gestión de estas técnicas fácil para el usuario.

Posee una colección de bibliotecas para técnicas de procesamiento previo y posterior para manipulación de datos, métodos de computación suave en conocimiento de extracción y aprendizaje y para proporcionar métodos de investigación científica.

Y ya que posee módulos de tratamiento de datos y análisis estadísticos, permite realizar un análisis completo de cualquier modelo de aprendizaje en comparación con los existentes, incluyendo un módulo de prueba estadística para la comparación.



Ilustración 3.2.11: Pantalla de inicio de KEEL.

Como se aprecia en la imagen, actualmente este software consta de los siguientes bloques funcionales: Data Management, Experiments, Educational.

- a) Data Management: La gestión de datos está compuesta por un conjunto de herramientas que pueden usarse para desarrollar nuevos datos, exportar e importar datos de otros formatos al formato de KEEL, edición y visualización de datos, aplicar transformaciones, partición de datos, etc.
- b) Experiments (Módulo off-line): El objetivo de esta parte es el diseño de la experimentación deseada a través de los conjuntos de datos seleccionados. Proporciona opciones para muchas funciones, tales como, el tipo de validación, el tipo de aprendizaje (clasificación, regresión, aprendizaje no supervisado, el descubrimiento de subgrupos), etc.
- c) Educational (Módulo on-line): Con una estructura similar a la del módulo anterior (Experiments), nos permite diseñar un experimento que puede ser ejecutado paso a paso, con el fin de utilizar esto como una guía para mostrar el proceso de aprendizaje de un determinado modelo de uso de la plataforma con fines educativos.

3.2.8.3.2 Principales Características

KEEL es una herramienta de software desarrollado para ensamblar y utilizar distintos modelos de Data Mining. Las principales características KEEL son:

- Los Algoritmos Evolutivos (AE) son presentados en modelos predictivos, pre-procesamiento (característica evolutiva y la selección del conjunto de la formación) y post-procesamiento (ajuste evolutivo de las reglas difusas).
- Incluye algoritmos pre-procesamiento de los datos, que se proponen en la literatura especializada: la transformación de datos, la discretización, selección de características, técnicas de eliminación de valores nulos y técnicas de filtrado de los datos ruidosos.
- Cuenta con una biblioteca de estadísticas para analizar los resultados de los algoritmos. Se compone de un conjunto de pruebas estadísticas para analizar la normalidad de los resultados, así como también realiza comparaciones paramétricas y no paramétricas entre los algoritmos.
- Algunos algoritmos se han desarrollado mediante el uso de Java Class Library for Evolutionary Computation (JCLEC)²².
- Proporciona una interfaz fácil de usar, orientada al análisis de algoritmos.
- El software está destinado a crear experimentaciones que contienen múltiples conjuntos de datos y algoritmos conectados entre sí para obtener un resultado esperado. Los experimentos son independientemente scripts generados a partir de la interfaz de usuario para un funcionamiento off-line, en la misma u otras máquinas.

²² <http://jclec.sourceforge.net> JCLEC es un sistema de software de investigación para la Computación Evolutiva (EC).

- También permite crear experimentos en modo on-line, con el objetivo de brindar una ayuda educativa para conocer y aprender el funcionamiento de los algoritmos que vienen incluido en la herramienta.
- Contiene Knowledge Extraction Algorithms Library²³, destacando la incorporación de múltiples algoritmos de aprendizaje evolutivo, junto con los enfoques de aprendizaje clásicos.

Las principales técnicas incluidas son:

- *Modelos de aprendizaje de reglas evolutivas*: Incluye diferentes paradigmas del aprendizaje evolutivo.
- *Sistemas Difusos (Fuzzy)*: Incluye modelos de aprendizaje con un buen compromiso entre la exactitud y la interpretación.
- *Redes Neuronales Evolutivas*: Incluye evolución y poda en las redes neuronales, unidad de productos de redes neuronales y modelos de base radial.
- *Programación Genética*: Incluye algoritmos evolutivos que utilizan representaciones de árboles para la extracción de conocimiento.
- *Descubrimiento de subgrupos*: Incluye algoritmos para la extracción de reglas descriptivas sobre la base de patrones de descubrimiento de subgrupos.
- *Reducción de datos*: Incluye algoritmos evolutivos para la reducción de los datos.

²³ <http://www.keel.es/algorithms.php> sección de la página oficial de KELL, donde se puede encontrar una lista completa de todos los algoritmos que se han incluido dentro de la herramienta.

3.2.8.4 Otras

En el mundo de la minería de datos existen muchas herramientas para el desarrollo de sus modelos, sin embargo, algunas son de tipo libre (no comercial) y otras de tipo comercial. Como bien dijimos anteriormente WEKA y KEEL son dos software libres.

A continuación se explicarán brevemente algunas de las tantas herramientas de software que existen para el desarrollo de la minería de datos.

3.2.8.4.1 De tipo libre

- a) KNIME (Konstanz Information Miner): Es una plataforma de minería de datos que permite el desarrollo de modelos en un entorno visual. Está construido bajo la plataforma Eclipse, programado principalmente en Java y distribuido bajo la licencia de GNU-GPL.

Permite una fácil integración de nuevos algoritmos, manipulación de datos y métodos de visualización como modelos. Compatible con WEKA, también incluye métodos estadísticos a través del uso de la herramienta R. (Berthold y otros 2006).

- b) Orange: Es un software informático que opera en múltiples plataformas, sirve para realizar minería de datos y análisis predictivo desarrollado en la facultad de informática de la Universidad de Ljubljana (Eslovenia). Consta de varios componentes desarrollados en C++ que implementan algoritmos de minería de datos y se distribuye bajo la licencia GNU-GPL.

Los componentes pueden ser controlados a través de un entorno grafico o sino también incluye un entorno de secuencias de comandos para la creación de prototipos de nuevos algoritmos y esquemas de prueba utilizando Python. [4]

3.2.8.4.2 De tipo comercial

- a) SPSS Clementine: Es una herramienta estadística integrada de minería de datos, programada en Java, muy usada por las empresa que implementan minería de datos, tiene la capacidad para operar con grandes bases de datos, posee una sencilla interfaz y opera en múltiples plataformas, es capaz de trabajar distintas técnicas como reglas se asociación, regresión, clustering y clasificación, solo por mencionar algunas características. Es de código cerrado (Software propietario).

Además posee una arquitectura distribuida (cliente/servidor). El programa consiste en un módulo base y módulos anexos que se han ido actualizando constantemente con nuevos procedimientos estadísticos. Cada uno de estos módulos se compra por separado.

El 2009 IBM²⁴ compra este software, dándole más funcionalidades y ayudando a la organización que compre el software, a anticipar los cambios de manera que pueda planificar e implementar estrategias que mejoren los resultados dentro de la empresa, mediante la aplicación del análisis predictivo.

- b) STATISTICA: Es un paquete estadístico usado en el ámbito de la minería de datos, su primer aversión fue lanzada sobre MS-DOS. Dispone de un sistema propio de archivos y es un software no libre. Posee la característica de exportar sus modelos a otros formatos como XML, C/C++, Visual Basic, Java, SQL.

El programa consta de varios módulos. El principal de ellos es el Base, que implementa las técnicas estadísticas más comunes. Y además se complementa con otros módulos más específicos, tales como, “Advanced”, “QC”, “Data Miner”.

Esta última plataforma para Data Mining de STATISTICA ofrece el más amplio y eficiente sistema de herramientas intuitivas para todo el proceso de minería de sus datos. Además dispone de numerosos algoritmos y técnicas de Data Mining.

²⁴ International Business Machines (IBM) es una destacada empresa multinacional estadounidense de tecnología y consultoría en la industria de la informática, Armonk, NY 10504-1722, Estados Unidos (Teléfono: 800-426-4968, email: ews@us.ibm.com).

3.2.9 Ejemplos

Para comprender aún más la minería de datos, se ha finalizado este capítulo con un par de ejemplos muy sencillos, que dejarán más claro y ayudarán a la comprensión de este concepto tan importante.

3.2.9.1 Ejemplo 1 (Descriptivo): Análisis de la cesta de compra [2]

Un supermercado quiere obtener información sobre el comportamiento de compra de sus clientes. Piensa que de esta forma puede mejorar el servicio que les ofrece: reubicación de los productos que se suelen comprar juntos, localizar el emplazamiento idóneo para nuevos productos, etc. Para ello dispone de la información de los productos que se adquieren en cada una de las compras o cestas. Un fragmento de esta base de datos se muestra en la Tabla 1.

Id	Huevos	Aceite	Pañales	Vino	Leche	Mantequilla	Salmon	Lechuga	...
1	si	no	no	si	no	si	si	si	...
2	no	si	no	no	si	no	no	si	...
3	no	no	si	no	si	no	no	no	...
4	no	si	si	no	si	no	no	no	...
5	si	si	no	no	no	si	no	si	...
6	si	no	no	si	si	si	si	no	...
7	no	no	no	no	no	no	no	no	...
8	si	si	si	si	si	si	si	no	...
...

Tabla 3.2.1: Datos de las cestas de compra.

Analizando estos datos el supermercado podría encontrar, por ejemplo:

- El 100 por ciento de las veces que se compran pañales también se compra leche.
- El 50 por ciento de las veces que se compran huevos también se compra aceite.
- El 33 por ciento de las veces que se compra vino y salmón entonces se compran lechugas.

También se puede analizar cuáles de estas asociaciones son frecuentes, porque una asociación muy estrecha entre productos puede ser poco frecuente, y por tanto, poco útil.

Se infiere a través del análisis, que sería efectivo colocar en un pasillo las leches y posteriormente los pañales, aumentando la compra de dichos productos y cabe destacar que a este análisis se le denomina *Market Basket Analysis*, es decir, que productos son los que se compran juntos.

3.2.9.2 Ejemplo 2 (Predictivo): Análisis de créditos bancarios [2]

Un banco por internet desea obtener reglas para predecir que personas de las que solicitan un crédito no lo devuelven. La entidad bancaria cuenta con los datos correspondientes a los créditos concedidos con anterioridad a sus clientes (cuantía del crédito, duración en años, etc.) y otros datos personales como el salario del cliente, si posee casa propia, etc. Algunos registros de clientes de esta base de datos se muestran en la Tabla 2.

IDC	D-crédito (años)	C-crédito (euros)	Salario (euros)	Casa propia	Cuentas morosas	...	Devuelve-crédito
101	15	60000	2200	si	2	...	no
102	2	30000	3500	si	0	...	si
103	9	9000	1700	si	1	...	no
104	15	18000	1900	no	0	...	si
105	10	24000	2100	no	0	...	no
...

Tabla 3.2.2: Datos para un análisis de riesgo en créditos bancarios.

A partir de éstos, las técnicas de minería de datos podrían sintetizar algunas reglas, como por ejemplo:

SI Cuentas-Morosas > 0 **ENTONCES** Devuelve-crédito = no
SI Cuentas-Morosas = 0 **Y** [(Salario > 2500) **O** (D-crédito > 10)] **ENTONCES** Devuelve-crédito = si

Se concluye entonces que el banco podría utilizar estas reglas para determinar las acciones a realizar en el trámite de los créditos a futuro: si se concede o no el crédito solicitado, si es necesario pedir avales especiales, tomar otro tipo de acciones, etc.

4 PROCESO DE EXTRACCION DE CONOCIMIENTO

4.1 Elección de Enfoque, Técnicas y Algoritmos

Como ya se ha mencionado anteriormente en este proyecto, para obtener los diversos modelos, que son utilizados para hacer las predicciones, es necesario tomar una serie de decisiones antes de comenzar todo el proceso.

Es obligatorio determinar y elegir estas tres cosas con las que se va a desarrollar el proceso:

1. Elegir el tipo de tarea o enfoque a implementar.
2. Elegir las técnicas para obtener el modelo.
3. Elegir el algoritmo de minería de dato que resuelva la tarea y obtenga el tipo de modelo.

En las siguientes subsecciones, se ha argumentado el por qué la elección de los distintas decisiones mencionadas anteriormente.

4.1.1 Herramienta escogida

Dentro de las herramientas que se han averiguado y evaluado, hubo una que más destacó por sobre el resto, esta fue "WEKA", en varias encuestas, que se realizaron en el reconocido sitio de "kdnuggets"²⁵, se ha podido observar que es una de las herramientas libres mejor catalogadas en el transcurso de los años, esto debido a su potencial funcionamiento y su fácil aprendizaje de uso gracias a su interfaz gráfica de usuario.

Es el mejor software para llevar a cabo el proceso de Data Mining ya que principalmente es un software libre, además contiene muchas herramientas para los datos pre-procesamiento, clasificación, regresión, clustering, reglas de asociación, y visualización y entrega resultados gráficos e interpretables fácilmente.

²⁵ <http://www.kdnuggets.com/polls/2012/analytics-data-mining-big-data-software.html>

Se ha obtenido mucha documentación en internet, respecto al uso y manejo de la plataforma de aprendizaje WEKA, esto contrarresta el hecho de que este software no posea “Lenguaje Español”. Además, se han observado varios videos-tutoriales, haciendo aún más sencillo su uso, en repositorios web.

Otro fuerte que tiene, es que está disponible libremente bajo la licencia pública general de GNU, también es muy portable porque está completamente implementado en Java y puede correr en casi cualquier plataforma. Incluye una gran colección de técnicas para pre-procesamiento de datos y modelado.

Todas las técnicas que se pueden utilizar, se fundamentan en la aceptación de que los datos están disponibles en un fichero plano (flat file) o una relación, en la que cada registro de datos está descrito por un número fijo de atributos (numéricos, nominales u otros).

Otra útil ventaja, que no se ha tenido que manejar, pero que demuestra lo poderosa que es esta herramienta, es que proporciona acceso a bases de datos vía SQL gracias a la conexión JDBC (Java Database Connectivity)²⁶ y permite realizar consultas en este lenguaje directamente a la base de datos, en este caso, esta ventaja no ha influido en la elección de WEKA, ya que no se ha usado bases de datos en nuestro problema, solo se menciona en este informe, para respaldar que es un software poderoso y multifuncional.

WEKA parece ser una herramienta muy potente, que cuenta con muchas funcionalidades y características provechosas, sus algoritmos cubren casi todas las áreas de la minería de datos, excepto la del modelado de secuencias, pero que en este caso no ha sido requerido este modelado, en consecuencia, cumple con todo lo que se ha requerido aplicar.

²⁶ <http://docs.oracle.com/javase/tutorial/jdbc/overview/index.html> JDBC es una API que permite la ejecución de operaciones sobre bases de datos desde el lenguaje de programación Java.

4.1.2 Enfoques utilizados

Estas tareas resuelven problemas de tipo predictivo, que es lo que se busca, con el fin de adquirir conocimiento útil sobre los alumnos que están cursando o que van a cursar los ramos de primer año de programación.

No se ha utilizado el enfoque de Agrupamiento o Clusters, esto debido a que se han analizado datos que ya están etiquetados con una clase, en nuestro problema ya se conocen las clases, lo que se pretende es predecir valores futuros y saber a qué clase se clasificarán.

4.1.3 Técnicas y Algoritmos empleados

Mediante la herramienta escogida (WEKA), se han utilizado técnicas como reglas de clasificación y árboles de decisión, porque son más fáciles de tomar e interpretar la salida de los datos que se obtuvieron mediante los determinados algoritmos, puesto que los resultados obtenidos serán expresados como reglas de la forma “Si x ENTONCES y ”, detectando de esta forma a los alumnos con problemas y tomando una decisión pertinente para esos casos.

Los algoritmos escogidos en este proyecto y aplicados sobre las técnicas de Data Mining, son varios, entre ellos están los algoritmos de inducción de reglas de clasificación: JRip, NNge, OneR, Prism y Ridor. Asimismo se han usado algoritmos de árboles de decisión, tales como: J48, SimpleCart, NBTree, REPTree, ADTree y RandomTree. Diversos algoritmos que generar distintos modelos, algunos han sido comparado obteniéndose buenas conclusiones.

4.2 Documentación KDD

Para este problema, en particular, se ha utilizado el proceso de extracción de conocimiento en bases de datos propuesto por los autores Fayyad, Piatetsky-Shapiro, el cual lo definen como “*El proceso no trivial de identificar patrones válidos, nuevos, potencialmente útiles y en última instancia comprensible en los datos*”. En efecto, constará de las 5 etapas que ellos proponen, para llevar a cabo el proceso de minería de datos.

Se ha escogido por la importancia que estos autores le dan a la etapa de Pre-procesamiento de los datos, esta es una etapa independiente de gran consideración, ya que garantiza la calidad de los datos para el resultado final que se obtenga. A diferencia de los otros autores (Han y Kamber), que establecen la etapa de pre-proceso de los datos junto con la transformación y selección, restando importancia a esta etapa. A mi parecer es significativo tomar en cuenta el pre-procesamiento de los datos, como un paso aparte de los demás.

Es por esto que se ha optado por la elección del proceso KDD según los autores Fayyad, Piatetsky-Shapiro, declinando así la definición que dan Han y Kamber.

A continuación, se ha detallado el proceso KDD que se ha llevado a cabo en nuestra problemática.

4.2.1 Selección de datos

Una vez que se ha establecido el objetivo general y los objetivos específicos, todo esto con el fin de obtener conocimiento útil al final del proyecto. Se ha procedido a recopilar los datos de los alumnos, esto mediante los profesores del Departamento de Sistema de Información Manuel Crisosto y Christian Vidal, quienes han entregado los datos de varios cursos que ellos han impartido entre los años 2000-2012, conteniendo en ellos los alumnos con sus respectivas calificaciones (Certámenes, Test, Trabajo o Software, Nota de Presentación, Examen, etc.)

Además, en conjunto con el registro académico de la Universidad (Sede Concepción), mediante la profesora Gilda Vargas, se han facilitado más variables que puedan incidir en el rendimiento académico de los alumnos, esto para que las variables tuvieran un alcance mayor en el proceso KDD y se puedan inferir reglas aún más abundantes de contenido y que reflejen claramente lo que se pretende alcanzar.

Todas estas variables son importantes para adquirir información útil del comportamiento del alumno y así alertar a tiempo al profesor cuando un estudiante se encuentra en riesgo de reprobar la asignatura de programación.

Al provenir de distintas fuentes los datos, se ha tenido que unificar dichos datos, permitiendo observar de mejor manera lo que se iba a analizar. Esto es provechoso, ya que para quién trabaja en el proceso o alguien que observe los datos desde afuera, claramente va a tener una idea más evidente de que es lo que se va a examinar posteriormente.

Cabe recalcar, que todos los datos entregados por ambos profesores y por el Registro Académico han sido resguardados rigurosamente, manteniendo la privacidad de los mismos, a fin de evitar mal uso de ellos y solo ser usados con fines benéficos en este proyecto.

4.2.2 Pre-procesamiento de los datos

En esta etapa de gran trascendencia, que tiene por objetivo garantizar y mejorar la calidad de los datos que se han analizados, para que al final el conocimiento descubierto sea útil y novedoso.

Se han preparado y limpiado los datos de los archivos Excel, los que eran distintas secciones de los cursos de programación entre los años ya mencionados y tenían parte importante de las variables a estudiar.

Algunos problemas encontrados en el pre-procesamiento de los datos son:

Casos especiales y aislados de algunos alumnos que no se encontraban en la información que ha facilitado el registro académico, es decir, solo se tenía el nombre, rut y carrera del alumno, tampoco dichos alumnos contaban con mucha información en los archivos con datos que han otorgado los profesores, por ende, se ha optado por la eliminación de estas tuplas y la eliminación de datos inconsistentes.

Es así como también se han limpiado estos valores nulos, mediante el rechazo de las tuplas completamente vacías.

Se ha usado la reducción de datos, por medio de un estudio previo, y se ha considerado que variables de todas las que se tienen, son las que realmente pueden incidir en el rendimiento académico de los alumnos, algunas variables no tienen una gran consecuencia y no fueron tomadas en cuenta al momento en que ha convertido todo en una gran tabla, esto implica que al reducir la dimensión de la tabla final se ha evitado la entropía.

Luego de haber normalizado los datos, se genera el archivo "Excel_final.xls" con las 19 variables que determinen el comportamiento, en términos de la calificación final, de los alumnos del primer curso de programación y 1 variable correlativa.

La tabla única que se tiene, es el archivo "Excel_final", este registro contiene 19 variables incidentes en el desempeño académico, con sus respectivos datos y también posee una variable indicadora, para saber a qué alumno corresponden dichas notas, asistencia, etc.

Variable	Descripción
ID	Variable numérica, que funciona como correlativo para saber de qué alumno se trata, no incide en el rendimiento académico y no participa de las reglas generadas.
Carrera	Variable que indica la carrera del alumno.
PsuPaa	Variable de tipo numérica, que indica el puntaje de entrada a la Universidad.
PuntajeMat	Variable de tipo numérica, que indica el puntaje de matemáticas que obtuvo el alumno.
Nota	Variable de tipo numérica que está relacionada con la Nota de Enseñanza Media, que obtuvo el alumno.
Colegio	Variable de tipo numérica, que indica el grado del colegio del cual proviene un alumno (Particular, Subvencionado, Municipal).
TiempoEntrar	Variable de tipo numérica, que indica el número de años que se demoró en entrar a la Universidad, se calcula mediante la diferente entre el año de egreso de la enseñanza media y el año de ingreso a la educación

	superior.
Asistencia	Variable de tipo numérica, medida en términos porcentuales, e indica el porcentaje de un alumno al curso de programación.
Semestre	Variable de tipo numérica, que indica el semestre del año en el cual el alumno cursó la asignatura.
Profesor	Variable que indica el nombre del profesor que impartió el ramo.
Certamen1	Variable de tipo numérica, que indica la nota del alumno en el certamen 1.
Certamen2	Variable de tipo numérica, que indica la nota del alumno en el certamen 2.
Certamen3	Variable de tipo numérica, que indica la nota del alumno en el certamen 3, si es que se aplicó o no dicho certamen al curso.
NotaTest	Variable de tipo numérica, que indica la nota final de los test obtenida por el alumno.
Trabajo	Variable de tipo numérica, que indica la nota final del trabajo semestral obtenida por el alumno.
NotaPresentacion	Variable de tipo numérica, que indica la nota con que el alumno se presenta al final del curso. Determina si le corresponde rendir examen o no.
Examen	Variable de tipo numérica, que indica la nota obtenida en el examen, en caso de que el alumno lo haya rendido.
NotaFinal	Variable de tipo numérica, que indica la nota final del alumno en el curso, después de haber rendido examen (si es que correspondía).
TerminoRamo	Variable de tipo booleana, que hace alusión a si el alumno termino el ramo en el semestre que lo inscribió, de lo contrario se asume que lo renunció (V = terminó y F = No Terminó).
PrimeraSegunda	Variable de tipo numérica, que indica si es la primera o segunda vez que el alumno está tomando el curso.

Tabla 4.2.1: Descripción de las variables.

Finalizado el pre-proceso de los datos se obtiene una tabla con una buena y adecuada estructura, para pasar a la etapa de la transformación de los datos.

4.2.3 Transformación de los datos

Para facilitar el análisis y estudio de los datos se transforma el esquema de la tabla única que se dispone, por un esquema de etiquetado, en donde, los valores numéricos se han cambiado a formato nominal o categórico, cada variable se ha catalogado en una índole diferente, a excepción de todo lo que se relaciona con las notas, estas variables están clasificadas dentro de la misma escala.

A continuación, se dan a conocer las escalas con las que se produjeron las etiquetas correspondientes para cada variable incidente. En la columna de la izquierda aparece el dato con el que aparecían las variables y en la columna de la derecha, aparece la etiqueta por la cual fue sustituida.

1. Variable Carrera

CARRERA	
Datos	Etiqueta
Ingeniería Civil en Informática	ICI
Ingeniería (E) en Computación e Informática	IECI

Tabla 4.2.2: Etiquetado de la variable "Carrera".

Como se aprecia en la tabla 4.2.1, la carrera de Ingeniería Civil en Informática fue reemplazada o etiquetada por "ICI" y la carrera Ingeniería (E) en Computación e Informática por "IECI", para su posterior análisis.

2. Variable PsuPaa

PSU o PAA	
Datos	Etiqueta
150 – 449	MuyBajo
450 – 499	Bajo
500 – 649	Regular
650 – 749	Bueno
750 – 850	MuyBueno

Tabla 4.2.3: Etiquetado de la variable “PsuPaa”.

Esta tabla cataloga los puntajes obtenidos en la Prueba de Selección Universitaria (PSU), para los alumnos que han ingresado desde el año 2003 en adelante, y la Prueba de Aptitud Académica (PAA), para los alumnos que ingresaron a la Universidad hasta el año 2002.

3. Variable PuntajeMat

PUNTAJE MATEMATICAS	
Datos	Etiqueta
150 – 449	MuyBajo
450 – 499	Bajo
500 – 649	Regular
650 – 749	Bueno
750 – 850	MuyBueno

Tabla 4.2.4: Etiquetado de la variable “PuntajeMat”.

Esta tabla etiqueta los puntajes de la misma forma que se hizo con los puntajes de la PSU o PAA, clasificándolos en “MuyBajo”, “Bajo”, “Regular”, “Bueno” y “MuyBueno”, de acuerdo a lo visto en la tabla anterior.

4. Variable Nota

NOTAS DE ENSEÑANZA MEDIA (1 al 7)	
Datos	Etiqueta
1,0 – 3,0	MuyBajo
3,1 – 3,9	Bajo
4,0 – 5,0	Regular
5,1 – 6,0	Bueno
6,0 – 7,0	MuyBueno

Tabla 4.2.5: Etiquetado de la variable "Nota".

Esta tabla etiqueta a las notas (con escala de notas del 1 al 7), catalogándolos en "MuyBajo", "Bajo", "Regular", "Bueno" y "MuyBueno".

5. Variable Colegio

COLEGIO	
Datos	Etiqueta
1	Particular Pagado
2	Particular Subvencionado
3	Municipal

Tabla 4.2.6: Etiquetado de la variable "Colegio".

Esta tabla etiqueta los datos de colegio, catalogándolos en "Particular Pagado", "Particular Subvencionado" y "Municipal", esto de acuerdo al colegio del cual los alumnos provenían.

6. Variable TiempoEntrar

TIEMPO EN ENTRAR (años)	
Datos	Etiqueta
1 – 2	Normal
3 – 5	Mucho
6 – 17	Excesivo

Tabla 4.2.7: Etiquetado de la variable "TiempoEntrar".

Esta tabla etiqueta los datos del tiempo que se demoró en entrar a la universidad, catalogándolos en "Normal", "Mucho", "Excesivo".

7. Variable Asistencia

ASISTENCIA (%)	
Datos	Etiqueta
0 – 29	MuyBaja
30 – 59	Baja
60 – 74	Regular
75 – 94	Buena
95 – 100	MuyBuena
Just	Justificado
Celda Vacía	SinInformacion

Tabla 4.2.8: Etiquetado de la variable "Asistencia".

Esta tabla etiqueta los datos de la asistencia del alumno en el curso de programación, catalogándolos en "MuyBaja", "Baja", "Regular", "Buena" y "MuyBuena". Hay casos excepcionales, en donde las asistencias están justificadas previamente con el profesor y otros cursos en donde no se aplicó asistencia, por ende, se deja como etiquetado "Justificado" y "SinInformacion" respectivamente.

8. Variable Semestre

SEMESTRE	
Datos	Etiqueta
1	PrimerSem
2	SegundoSem
Celda Vacía	SinInformacion

Tabla 4.2.9: Etiquetado de la variable "Semestre".

Esta tabla etiqueta los datos del semestre en que se impartió el curso de programación, catalogándolos en "PrimerSem" y "SegundoSem". Hay ciertos cursos, donde la información que me entrego no se especificaba el semestre al cual pertenecía el curso, estas celdas se las etiqueto como "SinInformacion".

9. Variable Profesor

PROFESOR	
Datos	Etiqueta
Manuel Crisosto	MC
Christian Vidal	CV

Tabla 4.2.10: Etiquetado de la variable "Profesor".

Esta tabla etiqueta los datos del profesor que impartió el determinado curso, catalogándolos en "MC" en el caso que fuera el profesor Manuel Crisosto y "CV" en el caso que fuera el profesor Christian Vidal.

10. Variable Certamen 1

CERTAMEN 1 (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal

45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien
Celda Vacía	NoRinde

Tabla 4.2.11: Etiquetado de la variable "Certamen1".

Esta tabla etiqueta los datos de las notas de los alumnos que obtuvieron en el certamen 1, catalogándolos en “MuyMal”, “Mal”, “Regular”, “Bien” “MuyBien”. Hay ciertos alumnos que no rindieron el certamen 1 ya sea porque renunciaron la asignatura o por algún caso especial, en estos casos se les aplica el etiquetado de “NoRinde”.

11. Variable Certamen 2

CERTAMEN 2 (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal
45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien
Celda Vacía	NoRinde

Tabla 4.2.12: Etiquetado de la variable "Certamen2".

Esta tabla etiqueta los datos de las notas de los alumnos que obtuvieron en el certamen 2, catalogándolos en “MuyMal”, “Mal”, “Regular”, “Bien” “MuyBien”. Hay ciertos alumnos que no rindieron el certamen 2 ya sea porque renunciaron la asignatura o por algún caso especial, en estos casos se les aplica el etiquetado de “NoRinde”. Se aplica la misma escala que para el certamen 1.

12. Variable Certamen 3

CERTAMEN 3 (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal
45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien
Celda Vacía	NoAplica

Tabla 4.2.13: Etiquetado de la variable "Certamen3".

Esta tabla etiqueta los datos de las notas de los alumnos que obtuvieron en el certamen 3 (si es que se les fue aplicado), catalogándolos en “MuyMal”, “Mal”, “Regular”, “Bien” “MuyBien”. Hay ciertos alumnos que no se les aplico el certamen 3, debido a que el profesor decidió solo aplicar 2 certámenes. Es una variable que en general no se encuentra, pero que se consideró dentro de las variables influyentes en el rendimiento, para que posteriormente se evalúe si es más conveniente dictar el ramo aplicando 2 o 3 certámenes.

13. Variable NotaTest

NOTA FINAL TEST (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal
45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien
Celda Vacía	NoRinde

Tabla 4.2.14: Etiquetado de la variable "NotaTest".

Esta tabla etiqueta los datos del promedio final que obtuvieron los alumnos en los test, catalogándolos en “MuyMal”, “Mal”, “Regular”, “Bien” “MuyBien”. Hay ciertos alumnos que no tienen información en esta variable ya que quizás pueden haber renunciado la asignatura, en estos casos se les etiqueta como “NoRinde”.

14. Variable Trabajo

NOTA FINAL TRABAJO O SOFTWARE (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal
45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien
Celda Vacía	NoRinde

Tabla 4.2.15: Etiquetado de la variable "Trabajo".

Esta tabla etiqueta los datos del promedio final que obtuvieron los alumnos en los trabajos en clases, o en el trabajo semestral o en el software, dependiendo de lo que se haya implementado en dicho curso, catalogándolos en “MuyMal”, “Mal”, “Regular”, “Bien” “MuyBien”. Hay ciertos alumnos que no tienen información en esta variable ya que quizás pueden haber renunciado la asignatura, en estos casos se les etiqueta como “NoRinde”.

15. Variable NotaPresentacion

NOTA DE PRESENTACIÓN (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal
45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien

NCR	NoCumpleRequisitos
Celda Vacía	SinNota

Tabla 4.2.16: Etiquetado de la variable "NotaPresentacion".

Esta tabla etiqueta los datos de la nota de presentación del alumno antes del examen (si es que lo tuviese que rendir), catalogándolos en “MuyMal”, “Mal”, “Regular”, “Bien” “MuyBien”. Hay ciertos alumnos que no tienen información en esta variable ya que quizás pueden haber renunciado la asignatura, en consecuencia, no tendrán nota de presentación, en estos casos se les etiqueta como “SinNota”. También si algún alumno no cumplió con los requisitos mínimos del curso, es decir, faltó demasiado, cuando la asistencia para aprobar es el 75%, o si no fue a dar las evaluaciones, sin presentar algún tipo de justificación real, se le considera como NCR y se les etiqueta como “NoCumpleRequisitos”.

16. Variable Examen

EXAMEN (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal
45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien
Celda Vacía	NoRinde

Tabla 4.2.17: Etiquetado de la variable "Examen".

Esta tabla etiqueta los datos de la nota de examen del alumno, catalogándolos en “MuyMal”, “Mal”, “Regular”, “Bien” “MuyBien”. Hay ciertos alumnos que no tienen información en esta variable, debido a que simplemente no rindieron el examen, por el motivo de que se eximieron o simplemente no fueron a darlo, cuando suceden estos se les etiqueta como “NoRinde”.

17. Variable NotaFinal

NOTA FINAL (1 al 100)	
Datos	Etiqueta
1 – 44	MuyMal
45 – 59	Mal
60 – 70	Regular
71 – 89	Bien
90 – 100	MuyBien
NCR	NoCumpleRequisitos
Celda Vacía	SinNota

Tabla 4.2.18: Etiquetado de la variable "NotaFinal".

Esta tabla etiqueta los datos de la nota final que obtuvo el alumno, catalogándolos en "MuyMal", "Mal", "Regular", "Bien" "MuyBien". Hay ciertos alumnos que no tienen información en esta variable ya que quizás pueden haber renunciado la asignatura, en consecuencia, no tendrán nota y la celda estará vacía, en estos casos se les etiqueta como "SinNota". También si algún alumno no cumplió con los requisitos mínimos del curso, es decir, faltó demasiado, cuando la asistencia para aprobar es el 75%, o si no fue a dar las evaluaciones, sin presentar algún tipo de justificación real, se le considera como NCR y se les etiqueta como "NoCumpleRequisitos".

18. Variable TerminoS Rama

TERMINO EL RAMO	
Datos	Etiqueta
TRUE	SI
FALSE	NO

Tabla 4.2.19: Etiquetado de la variable "TerminoRamo".

Esta tabla etiqueta los datos del término de ramo, es decir, si el alumno terminó el ramo en el semestre que lo inscribió. Si es así y el alumno terminó el ramo, la etiqueta será "SI",

de lo contrario si el alumno no termino el ramo, por diferentes motivos, la etiqueta será “NO”.

19. Variable PrimeraSegunda

Datos	Etiqueta
1	Primera
2	Segunda

Tabla 4.2.20: Etiquetado de la variable "PrimeraSegunda".

Esta tabla etiqueta los datos de la nota de examen del alumno, catalogándolos en “Primera” y “Segunda”, de acuerdo, a si es primera o segunda vez que cursa la asignatura de programación.

Cabe destacar, algo no menor dentro de esta etapa, es que después del etiquetado se guarda el archivo con el formato “.CSV (*delimitado por comas*)”, este formato es un tipo de archivo que guarda los datos separados por puntos y comas, estos ya han sido transformados para que más tarde puedan ser reconocidos sin problema por la herramienta WEKA. Software con el cual trabajaremos todos los datos y aplicaremos las técnicas de minería de datos.

Como se observa se hace por tanto necesario un pre-procesamiento previo a la transformación, en el que se disminuya el tamaño del conjunto almacenado. Así se han consolidado los datos de una forma apropiada y necesaria para la siguiente etapa del proceso KDD.

4.2.4 Minería de datos

Una vez que se ha revisado el conjunto de datos y el número de instancias de las clases “Aprobo” y “Reprobo”, se encuentra **balanceado**, es decir, el número de alumnos aprobados es muy similar al de reprobados, tal cual se observa en la siguiente imagen,

donde la clase “Aprobo” tiene 255 instancias mientras que la clase “Reprobo” posee 256 instancias.




Ilustración 4.2.1: Grafico del atributo “NotaFinal” que se encuentra balanceado.

Al estar balanceados los datos, nos evitamos que los algoritmos de clasificación tengan en su etapa de entrenamiento una clase mayoritaria, lo que lleva a clasificar en la etapa de prueba con baja sensibilidad a los elementos de la clase minoritaria. También se ha desechado de utilizar algún filtro o algoritmo que posea WEKA para poder balancear el conjunto de datos.

Después de realizar las tareas de pre-proceso y transformación de los datos, se observa que se cuenta con:

1. Los 10 ficheros de entrenamiento y testeo con los 19 atributos influyentes.
2. Los 10 ficheros de entrenamiento y testeo con los 19 atributos influyentes considerando los costos de clasificación.
3. Los 10 ficheros de entrenamiento y testeo con los atributos que inciden hasta el certamen 1.
4. Los 10 ficheros de entrenamiento y testeo con los atributos que inciden hasta el certamen 2.

Se han descrito estos 4 experimentos y las técnicas de minería de datos que han sido utilizadas para la obtención de los modelos de predicción del rendimiento académico de los estudiantes.

Estos son realizados con el objetivo de obtener la máxima exactitud de clasificación y obtener reglas interesantes.

Para el experimento 1, se han tomado 10 algoritmos de clasificación disponibles por la herramienta seleccionada (WEKA), considerando todos los atributos influyentes, mediante la obtención de árboles de decisión y reglas de clasificación, se han conseguido reglas de interés y de fácil comprensión, para que puedan ser leídas por cualquier usuario no experto en el tema. Todo va enfocado a que al final de todo el proyecto, un profesor cualquiera, pueda hacer uso de este conocimiento entregado a través de las reglas obtenidas.

Las reglas son de manera simple, con un antecedente y un consecuente, son del tipo Si – Entonces, y son fácilmente comprensibles de presentar el conocimiento. Las reglas determinan una instancia de datos a la clase señalada por el consecuente, si es que los atributos de predicción satisfacen las condiciones declaradas en el antecedente.

También se han obtenido árboles con nodos internos y nodos hojas, este modelo predictivo en el cual una instancia es clasificada siguiendo un camino de condiciones cumplidas desde la raíz hasta llegar a una hoja, la cual va a corresponder a una clase etiquetada. Hay que mencionar que un árbol de decisión puede convertirse fácilmente a una regla de clasificación.

Los 10 algoritmos utilizados son: Jrip, NNge, OneR, Prism y Ridor, todo estos pertenecientes a la inducción de reglas de clasificación, y ADTree, J48, REPTree, SimpleCart y NBTree, pertenecientes a los árboles de decisión.

El fichero de datos fue particionado en 10 particiones (ficheros de entrenamiento y ficheros de prueba o testing), mediante la opción de “Crossvalidation”, que lo que hace es calcular el porcentaje de aciertos esperado haciendo una validación cruzada de “k” hojas (donde “k” es el número de particiones).

Para el segundo experimento, se ha abordado de una forma diferente, ya que se ha realizado una “clasificación sensible al costo”, esto quiere decir que ha intentado mejorar

el porcentaje de aciertos de la clase “Reprobo”, utilizando un meta-clasificador. Es un meta-clasificador, porque utiliza a otro clasificador base.

La herramienta WEKA permite realizar clasificación teniendo en cuenta el costo, para lo cual se ha utilizado el CostSensitiveClassifier, asociándole una matriz de costo y el clasificador a utilizar, de tal manera que se cosechen mejores resultados de clasificación.

Los primeros dos experimentos, tienen por objetivo principal alcanzar la máxima exactitud de clasificación posible, para que cuando sea añadido una nueva instancia (alumno), se pueda predecir la clase a la que pertenecerá.

Para el tercer experimento, se han considerado solo 11 variables, estas son: Carrera, PsuPaa, Nota, PuntajeMat, Asistencia, TiempoEntrar, Semestre, Profesor, Colegio, Certamen1 y NotaFinal. Lo que se pretende buscar es mediante las reglas de clasificación y árboles de decisión, obtener reglas que puedan aportar y alertar a tiempo al profesor, es decir, solo se considera hasta el certamen 1, para en un futuro cuando se haga uso de la aplicación, con solo tener la nota del certamen 1, se pueda inferir, dentro de que clase está clasificado el alumno. (“Aprobo” y “Reprobo”). Esto sin duda, ayudará a que el profesor pueda tener en consideración dichos alumnos y tome decisión pertinentes para mejorar obviamente su rendimiento académico.

Para el cuarto y último experimento, se ha añadido una variable más con respecto al experimento anterior, estas variables son: Certamen2, esto con el fin de encontrar reglas importantes y ricas en contenido, para cuando el alumno ya haya rendido el certamen 1 y el certamen 2, el objetivo de estos dos experimentos (3 y 4), es posteriormente analizarlos y determinar cuándo es más pertinente que el profesor tome una acción positiva con el fin de influir en el rendimiento de los estudiantes, mejorando así su desempeño académico.

Para estos dos últimos experimentos (3 y 4), se han implementado 4 algoritmos, estos son los siguientes: SimpleCart, J48, PART y Ridor.

4.2.5 Interpretación/Evaluación de resultados.

En esta sección se ha decidido mostrar y comentar los diversos modelos obtenidos, que han sido generados por medio de los algoritmos que mejores resultados de clasificación han obtenido en la etapa de minería de datos.

Los mejores algoritmos que se han experimentado, obteniendo los mejores resultados después del experimento 2, fueron: OneR (Ver Tabla 4.2.21), Prism (Ver Tabla 4.2.22) y J48 (Ver Tabla 4.2.23).

<p>NotaPresentacion: Regular-> Aprobo Mal -> Reprobo MuyMal-> Reprobo NoCumpleRequisitos -> Reprobo SinNota-> Reprobo Bien -> Aprobo MuyBien-> Aprobo (500/511 instances correct)</p>
--

Tabla 4.2.21: Reglas obtenidas usando OneR y considerando el costo de la clasificación.

En la tabla 4.2.21 se observan que el algoritmo OneR descubre pocas reglas y de un solo atributo (NotaPresentacion), dando a conocer reglas lógicas de las clases de este atributos, y las clasifica con respecto a las clases del atributo NotaFinal.

<p>If NotaPresentacion = Regular then Aprobo If NotaPresentacion = Bien then Aprobo If NotaPresentacion = MuyBien then Aprobo If Certamen2 = Bien then Aprobo If Examen = Bien and Certamen3 = NoAplica then Aprobo If Examen = Regular and Certamen2 = Mal then Aprobo If Examen = Regular and Semestre = SegundoSem then Aprobo If Examen = Bien and Asistencia = Buena then Aprobo If Examen = Regular and Certamen1 = Mal then Aprobo If Examen = Regular and Carrera = ICI</p>
--

```

and Asistencia = SinInformacion then Aprobo
If Examen = Mal
  and Trabajo = NoRinde then Aprobo
If NotaTest = MuyBien
  and Certamen2 = Mal then Aprobo
If Examen = Regular
  and NotaTest = Regular
  and Carrera = IECI then Aprobo
If Certamen1 = MuyBien
  and PuntajeMat = Bueno then Aprobo
If NotaTest = Bien
  and Trabajo = MuyBien
  and Colegio = Subvencionado then Aprobo
If NotaTest = Regular
  and Examen = MuyMal
  and PuntajeMat = Bueno then Aprobo
If Examen = Mal
  and NotaTest = Bien
  and TiempoEntrar = Mucho
  and Nota = MuyBien then Aprobo
If NotaTest = Regular
  and TiempoEntrar = Mucho
  and Carrera = ICI then Aprobo
If Examen = MuyMal
  and NotaTest = Regular
  and Trabajo = MuyBien
  and Nota = MuyBien then Aprobo
If NotaTest = Bien
  and Trabajo = NoRinde
  and Colegio = Municipal
  and Nota = Bien
  and TiempoEntrar = Normal then Aprobo

```

Tabla 4.2.22: Reglas (de tipo Aprobó) obtenida usando Prism y considerando el costo de clasificación.

En las reglas de la Tabla 4.2.22, se observa que este algoritmo descubre una gran cantidad de reglas. También se observa, que genera varias reglas interesantes que hay que tomar en cuenta a la hora de la elaboración del prototipo, donde se aplicaran dichas reglas, para mostrar en pantalla a que clase pertenece el alumno.

SI NotaTest = Regular **Y** TiempoEntrar = Mucho **Y** Carrera = ICI **ENTONCES** Aprobo

SI Certamen1 = MuyBien **Y** PuntajeMat = Bueno **ENTONCES** Aprobo

SI Certamen2 = Bien **ENTONCES** Aprobo

La segunda reglas nos dice, que si el alumno tiene habilidades en matemática, o sea, ha obtenido buen puntaje en la PSU de Matemáticas y que además en el certamen 1 le fue muy bien, entonces está clasificado dentro de los aprobados. Esta regla fácilmente se puede complementar con las reglas obtenidas en el experimento 4.

NotaPresentacion = Regular: Aprobado (113.0)
NotaPresentacion = Mal
Examen = NoRinde: Reprobado (22.0)
Examen = MuyMal: Reprobado (26.0/4.0)
Examen = Mal
Colegio = Subvencionado: Reprobado (5.0)
Colegio = Municipal
Semestre = PrimerSem: Aprobado (0.0)
Semestre = SinInformacion
Certamen2 = Regular: Reprobado (0.0)
Certamen2 = MuyMal: Aprobado (3.0/1.0)
Certamen2 = Mal: Reprobado (2.0)
Certamen2 = NoRinde: Reprobado (0.0)
Certamen2 = MuyBien: Reprobado (0.0)
Certamen2 = Bien: Reprobado (0.0)
Semestre = SegundoSem: Aprobado (3.0)
Colegio = ParticularPag: Reprobado (1.0)
Examen = Regular
TiempoEntrar = Mucho: Reprobado (2.0)
TiempoEntrar = Normal: Aprobado (10.0/1.0)
TiempoEntrar = Excesivo: Aprobado (0.0)
Examen = Bien: Aprobado (4.0)
Examen = MuyBien: Reprobado (3.0)
NotaPresentacion = MuyMal: Reprobado (177.0/5.0)
NotaPresentacion = NoCumpleRequisitos: Reprobado (15.0)
NotaPresentacion = SinNota: Reprobado (10.0)
NotaPresentacion = Bien: Aprobado (100.0)
NotaPresentacion = MuyBien: Aprobado (15.0)

Tabla 4.2.23: Árbol obtenido usando J48 y considerando el costo de clasificación.

En el árbol de decisión de la Tabla 4.2.23, se observa que tiene como nodo raíz, el atributo “NotaPresentacion”, siendo sus hojas, las clases del atributo “NotaFinal” (Ver imagen 4.2.2). También se obtienen buenas reglas que hay que considerar y prestar importancia.

SI NotaPresentacion = Mal **Y** Examen = Mal **Y** Colegio = Municipal **Y** Semestre = SinInformacion **Y**
Certamen2 = Bien **ENTONCES** Reprobo

SI NotaPresentacion = Mal **Y** Examen = Mal **Y** Colegio = Municipal **Y** Semestre = SegundoSem
ENTONCES Aprobo

SI NotaPresentacion = Mal **Y** Examen = Mal **Y** Colegio = ParticularPag **ENTONCES** Reprobo

SI NotaPresentacion = Mal **Y** Examen = Mal **Y** Colegio = Subvencionado **ENTONCES** Reprobo

SI NotaPresentacion = Mal **Y** Examen = Regular **Y** TiempoEntrar = Normal **ENTONCES** Aprobo

SI NotaPresentacion = Mal **Y** Examen = Regular **Y** TiempoEntrar = Mucho **ENTONCES** Reprobo

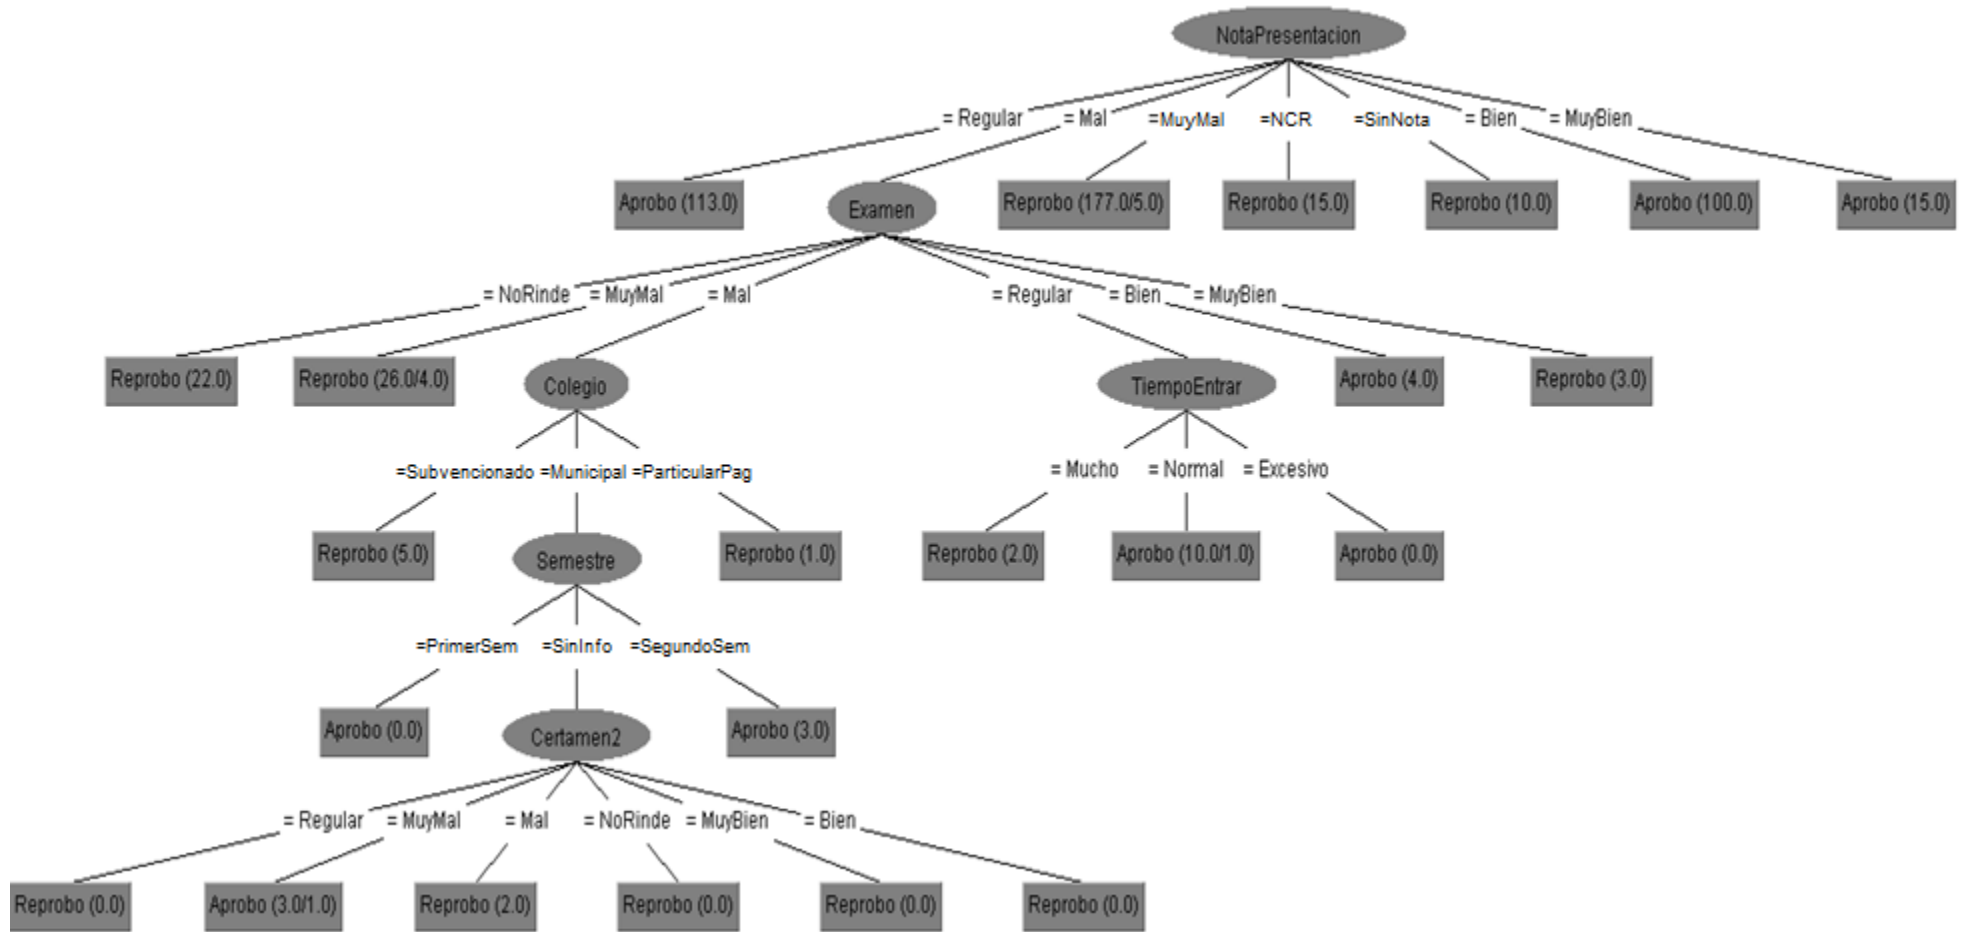


Ilustración 4.2.2: Árbol obtenido por el algoritmo J48.

En el caso del experimento 3, donde se pretende dar una solución después de saber la nota del certamen 1, cuando aún hay tiempo de beneficiar el rendimiento del alumno, se generan diversas reglas y conclusiones propicias para los estudiantes. Se han detallado a continuación:

```

Certamen1 = Mal
| Carrera = ICI
| | Semestre = PrimerSem
| | | Profesor = MC: Aprobo (15.0/4.0)
| | | Profesor = CV: Reprobo (6.0/1.0)
| | Semestre = SinInformacion: Aprobo (18.0/5.0)
| | Semestre = SegundoSem: Aprobo (0.0)
| Carrera = IECI: Reprobo (48.0/14.0)
Certamen1 = Bien: Aprobo (111.0/25.0)
Certamen1 = MuyMal: Reprobo (168.0/29.0)
Certamen1 = MuyBien: Aprobo (71.0/8.0)
Certamen1 = Regular: Aprobo (61.0/23.0)
Certamen1 = NoRinde: Reprobo (13.0)

```

Tabla 4.2.24: Reglas obtenidas usando el algoritmo J48.

SI Certamen1 = Mal **Y** Carrera = ICI **Y** Semestre = PrimerSem **Y** Profesor = MC **ENTONCES**
Aprobo

SI Certamen1 = Mal **Y** Carrera = ICI **Y** Semestre = PrimerSem **Y** Profesor = CV **ENTONCES**
Reprobo

Esto se puede deber, a que el profesor Manuel Crisosto ha impartido más cursos de programación en la carrera de Ingeniería Civil en Informática, por ende, tiene más probabilidades de cumplir con la primera regla y que el resultado final sea de que el alumno haya "Aprobado".

SI Certamen1 = Mal **Y** Carrera = ICI **Y** Semestre = SegundoSem **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Mal **Y** Carrera = IECI **ENTONCES** NotaFinal = Reprobo

Como se aprecia, al comenzar con el certamen 1 con una mala nota, se tiende a pensar que podría seguir esa tendencia y termina con mala nota final, pero todo depende de los otros atributos, en la primera regla influye el semestre, si le va mal en el primer certamen y es el segundo semestre en el cuál ha cursado el ramo, tiene muchas opciones de pasar el ramo, esto debido a que lo más probable es que el primer semestre, haya renunciado el ramo o simplemente lo reprobó, entonces vendría siendo la segunda vez que este alumno toma la asignatura.

En cambio sí le fue mal en el certamen 1 y pertenece a la carrera de Ingeniera Ejecución en Computación e Informática, tajantemente la regla dice que reprueba el ramo, acá todo claramente va a depender a la carrera que pertenezca el alumno (IECI o ICI).

En conclusión, se puede decir que si le fue mal en el primer certamen, tiene muchas posibilidades de aprobar aún el ramo, en cambio, no es así el caso cuando no rinde o le va muy mal en el certamen 1, lo más probable es que termine reprobando el ramo.

Son estas reglas las que ya nos permiten ir visualizando a qué clase de la nota final serán clasificadas las instancias, es así como el profesor por medio de este conocimiento nuevo adquirido a través de las reglas que nos proporcionó el algoritmo J48, puede tomar medidas favorable en el desempeño del alumno.

Sigamos mostrando más reglas que generan los otros algoritmos y que también nos sirven en consideración de los que se pretende alcanzar.

```
Certamen1=(NoRinde)|(MuyMal)|(Mal)
| Certamen1=(NoRinde)|(MuyMal)|(Bien)|(MuyBien)|(Regular): Reprobo(152.0/29.0)
| Certamen1!=(NoRinde)|(MuyMal)|(Bien)|(MuyBien)|(Regular)
| | Carrera=(IECI): Reprobo(34.0/14.0)
| | Carrera!=(IECI): Aprobo(25.0/14.0)
Certamen1!=(NoRinde)|(MuyMal)|(Mal): Aprobo(187.0/56.0)
```

Tabla 4.2.25: Reglas generadas por el algoritmo SimpleCart.

Acá se generan reglas en base al Certamen1, nuevamente, demostrando que este atributo es importante, en este experimento.

Encontramos reglas como:

SI Certamen1 = MuyBien **O** Certamen1 = Bien **O** Certamen1 = Regular **ENTONCES** NotaFinal = Aprobado

SI Certamen1 = Mal **Y** Carrera = IECI **ENTONCES** NotaFinal = Reprobado

SI Certamen1 = Mal **Y** Carrera = ICI **ENTONCES** NotaFinal = Aprobado

Nuevamente el Certamen1 y la carrera son atributos que hacen la diferencia entre una regla y otra, derivando a que clases pertenecerá el resultado de dichas reglas.

Ahora probamos con el algoritmo "Ridor", y se obtienen más reglas interesantes.

NotaFinal = Reprobado (511.0/255.0)
 Except (Certamen1 = MuyBien) and (Profesor = CV) => NotaFinal = Aprobado (17.0/0.0) [11.0/0.0]
 Except (Certamen1 = Bien) and (Carrera = ICI) and (Colegio = Municipal) and (TiempoEntrar = Normal) =>
 NotaFinal = Aprobado (16.0/0.0) [13.0/3.0]
 Except (Certamen1 = Bien) => NotaFinal = Aprobado (57.0/16.0) [25.0/6.0]
 Except (Certamen1 = MuyBien) and (Carrera = ICI) => NotaFinal = Aprobado (18.0/2.0) [8.0/1.0]
 Except (Certamen1 = Regular) and (Asistencia = SinInformacion) and (Profesor = MC) and (Colegio = Municipal)
 => NotaFinal = Aprobado (5.0/0.0) [2.0/1.0]
 Except (Certamen1 = Regular) and (TiempoEntrar = Normal) and (Colegio = Subvencionado) and (Carrera = ICI) =>
 NotaFinal = Aprobado (6.0/0.0) [4.0/1.0]
 Except (Certamen1 = Regular) and (PrimeraSegunda = Segunda) => NotaFinal = Aprobado (4.0/0.0) [1.0/0.0]
 Except (Certamen1 = Mal) and (Carrera = ICI) => NotaFinal = Aprobado (27.0/9.0) [12.0/5.0]
 Except (Certamen1 = MuyBien) and (Asistencia = SinInformacion) => NotaFinal = Aprobado (4.0/0.0) [3.0/1.0]

Tabla 4.2.26: Reglas obtenidas del algoritmo Ridor.

Se han encontrado las siguientes reglas interesantes:

SI Certamen1 = Bien **Y** Carrera = ICI **Y** Colegio = Municipal **Y** TiempoEntrar = Normal **ENTONCES**
 NotaFinal = Aprobado

SI Certamen1 = Regular **Y** Asistencia = SinInformacion **Y** Profesor = MC **Y** Colegio = Municipal
ENTONCES NotaFinal = Aprobado

SI Certamen1 = Regular **Y** TiempoEntrar = Normal **Y** Colegio = Subvencionado **Y** Carrera = ICI
ENTONCES NotaFinal = Aprobado

SI Certamen1 = Regular **Y** PrimeraSegunda = Segunda **ENTONCES** NotaFinal = Aprobado

SI Certamen1 = Mal **Y** Carrera = ICI **ENTONCES** NotaFinal = Aprobado

Uno tiende a pensar equívocamente que un alumno proveniente de un establecimiento municipal, tiene más posibilidades de reprobar que de aprobar el ramo, esto debido al trato y a la modalidad de educación que reciben estos establecimientos en nuestro país, y además porque la gente estigmatiza a los alumnos provenientes de liceos públicos.

Queda evidenciado que esto no siempre es así, ya que como se aprecia en las reglas obtenidas anteriormente, los alumnos provenientes de colegios municipales al mezclarse y relacionarse con otros factores o atributos, el resultado fue positivo, es decir, han terminado aprobando el ramo.

La carrera ya es un atributo importante junto con el certamen 1, los alumnos de ICI tienen más posibilidades de aprobar el ramo, dependiendo del certamen 1, esto se comprueba con la última regla que estipula lo siguiente: si él alumno obtuvo mala nota en el certamen 1, pero pertenece a la carrera de ICI, el alumno terminará aprobando el curso de programación.

Para el último experimento solo se añade la variable de "Certamen2".

5 RESULTADOS OBTENIDOS

En este capítulo se muestran los resultados que se obtuvieron mediante el WEKA para los 4 experimentos que ya se describieron en el capítulo anterior.

5.1 Experimento 1: Validación Cruzada utilizando todos los atributos

En este primer experimento se han ejecutados los 10 algoritmos (5 de reglas de clasificación y 5 de árboles de decisión), utilizando todas las 16 variables de todos los alumnos (511). Luego se ha procedido a aplicar una validación cruzada con 10 particiones, como viene predeterminado en el WEKA.

Cuando se aplica validación cruzada en los diferentes experimentos, lo que se hace es que se realiza el entrenamiento y la prueba 10 veces con las distintas particiones y los resultados que se obtienen son las media de las 10 ejecuciones.

Estos resultados están reflejados en la siguiente tabla, donde se indica el algoritmo que se ha utilizado, el Porcentaje de aciertos de la clase “Aprobo”, el Porcentaje de aciertos de la clase “Reprobo”, el porcentaje de precisión total del algoritmo y el promedio ponderado

Algoritmo	Porcentaje de Aciertos Aprobó	Porcentajes de Aciertos Reprobó	Porcentaje de Precisión	Promedio Ponderado
JRip	92,5	94,9	93,73	93,7
NNge	94,1	92,2	93,15	93,2
OneR	89,4	100	94,71	94,7
Prism	95,6	93,2	91,78	94,4
Ridor	91,8	98,4	95,10	95,1
J48	94,9	96,9	95,89	95,9
SimpleCart	91,8	94,1	92,95	93,0
ADTree	93,3	93,8	93,54	93,5
REPTree	91,4	98,8	95,10	95,1
NBTree	93,7	94,9	94,32	94,3

Tabla 5.1.1: Validación Cruzada de todos los atributos.

Puede observarse en la tabla anterior que los porcentajes de exactitud o precisión obtenidos para los Reprobados son más altos que los de Aprobados. Los algoritmos que consiguen los valores más altos en cada columna están destacados en negrita y son: OneR (para los porcentajes de aciertos en la clase “Reprobó”), Prism (para los porcentajes de aciertos en la clase “Aprobó”) y el algoritmo de árbol de decisión J48 (para los porcentajes de “Precisión” y “Promedio Ponderado”).

5.2 Experimento 2: Validación cruzada utilizando todos los atributos y considerando el costo de clasificación

En este experimento se pretende mejorar los porcentajes de aciertos para cada clase. Cuando se quiere optimizar la tasa de clasificación sin tomar en cuenta el costo de los errores, a menudo se pueden llegar a resultados no óptimos, debido al elevado costo que puede causar la mala clasificación de una instancia.

A los 10 algoritmos se les ha aplicado una clasificación sensible al costo, después de varias pruebas en cada algoritmo se ha encontrado una matriz de costos, que permite obtener los mejores resultados de clasificación. Esto se refleja en la siguiente tabla.

Algoritmo	Porcentaje de Aciertos Aprobó	Porcentajes de Aciertos Reprobó	Porcentaje de Precisión	Promedio Ponderado
JRip	89,4	98,8	94,12	94,1
NNge	91,8	96,1	93,93	93,9
OneR	89,4	100	94,71	94,7
Prism	95,3	95,1	93,15	95,2
Ridor	90,6	99,2	94,91	94,9
J48	92,9	98,0	95,49	95,5
SimpleCart	94,1	96,5	95,30	95,3
ADTree	93,3	94,1	93,73	93,7
REPTree	91,4	98,4	94,91	94,9
NBTree	92,5	98,0	95,30	95,3

Tabla 5.2.1: Validación Cruzada de todos los atributos considerando el costo de clasificación.

Al comparar la tabla 5.1.1 con la tabla 5.2.1, se ha podido inferir que los resultados obtenidos en la segunda tabla, en la cual se ha considerado el costo de clasificación, han aumentado su porcentaje de acierto de “Reprobo” en los diversos algoritmos tomados como ejemplo, pero han disminuido en la mayoría el porcentaje de precisión y el porcentaje de acierto de “Aprobo”. Esto es favorable, en el sentido que se sabrá con mayor precisión cuales son los alumnos más vulnerables, dándole a conocer al profesor, mediante las reglas y arboles obtenidos por estos algoritmos, cuáles son las variables más influyentes en el rendimiento final del alumno.

5.3 Experimento 3: Validación Cruzada usando los atributos hasta el Certamen 1

El objetivo de este experimento es obtener reglas que ayuden a detectar, hasta que se ha rendido el certamen 1, algunos patrones que permitan mostrar los atributos que en conjunto influyen en el rendimiento del alumno de formar positiva como negativa.

Hay que considerar que solo se toman en cuenta ciertos atributos, siendo el primordial de ellos el certamen 1, para luego inferir la clase de la nota final a la cual pertenecerá (Aprobó o Reprobó).

Al implementar y probar los 4 algoritmos de clasificación, se infieren algunas reglas interesantes, y que probablemente servirán de base en la elaboración del prototipo final.

SI Certamen1 = Mal **Y** Carrera = ICI **Y** Semestre = SegundoSem **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Mal **Y** Carrera = IECI **ENTONCES** NotaFinal = Reprobo
SI Certamen1 = MuyBien **O** Certamen1 = Bien **O** Certamen1 = Regular **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Mal **Y** Carrera = ICI **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Bien **Y** Carrera = ICI **Y** Colegio = Municipal **Y** TiempoEntrar = Normal **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Regular **Y** Asistencia = SinInformacion **Y** Profesor = MC **Y** Colegio = Municipal **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Regular **Y** TiempoEntrar = Normal **Y** Colegio = Subvencionado **Y** Carrera = ICI **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Regular **Y** PrimeraSegunda = Segunda **ENTONCES** NotaFinal = Aprobo
SI Certamen1 = Mal **Y** Carrera = ICI **ENTONCES** NotaFinal = Aprobo

Al tener los datos que genera el WEKA en reglas como las obtenidas en este experimento, es mucho más fácil evaluar e influir en el desempeño de los alumnos. Todos estos resultados obtenidos se dan a que la selección de algoritmos fueron todos de tipo “Caja Blanca”, es decir, se obtiene un modelo de salida comprensible para el usuario común y corriente.

6 PROTOTIPO O APLICACION

6.1 Diseño de interfaz y navegación

APLICACION DE TECNICAS DE DATA MINING AL RENDIMIENTO ACADEMICO DEL PRIMER CURSO DE PROGRAMACION DE COMPUTADORES

Ingrese las variables correspondientes del alumno.

*Nombre

*Carrera Ingeniería Civil en Informática
 Ingeniería de Ejecución en Computación e Informática

PSU Puntaje Matemáticas Nota de Enseñanza Media

Tipo de Colegio Particular Pagado
 Particular Subvencionado
 Municipal

Tiempo en entrar

Semestre Primero Segundo
 Vez que cursa el ramo Primera Vez Segunda Vez Tercera Vez

Profesor Asistencia (%)

Nota Test Trabajo *Certamen 1 Certamen 2

Borrar

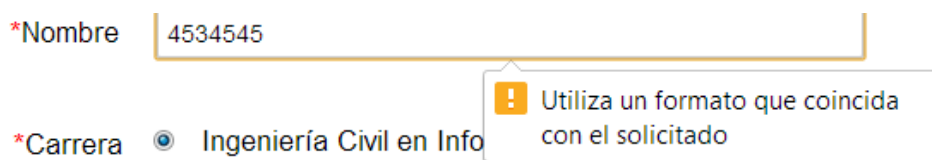
Resultado

Los campos marcados con un (*) son obligatorios

En la ilustración 6.1.1 se muestra la pantalla inicial de la aplicación (index.html), donde no es más que un formulario para ingresar todas las variables del alumno y así después a través de las reglas obtenidas por los algoritmos pertinentes, evaluar y clasificar a que clase pertenece el alumno.

La aplicación está hecha en el lenguaje de programación HTML (HyperText Markup Language), principalmente aprovechando las herramientas nuevas que facilita HTML5. La hoja de estilo se ha elaborado mediante CSS3 (Cascading Style Sheets), esta versión de CSS ofrece una gran variedad de opciones importantes y avanzadas para el diseño de la web, las que he usado y aprovechado enormemente. Y para recoger los datos de los campos y luego analizarlos en las distintas reglas obtenidas, he utilizado el popular lenguaje de código abierto, PHP (Hypertext Preprocessor).

Los campos con un asterisco (*) son de orden obligatorio, es decir sí o sí van a tener que estar para poder posteriormente ser analizados por la reglas. Cabe destacar, que todos los input donde se ingresan los datos, traen sus respectivas validaciones para el formato correcto, validaciones para los campos obligatorios y validaciones para que no se ingresen valores superiores o inferiores a ciertos números (en el caso de las notas y los puntajes), tal cual se aprecian en las siguientes imágenes:

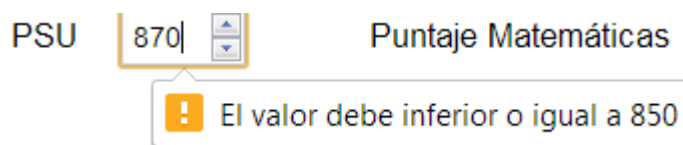


*Nombre 4534545

*Carrera Ingeniería Civil en Info

Utiliza un formato que coincida con el solicitado

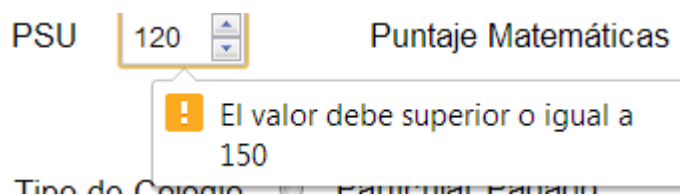
Ilustración 6.1.2: Validación para el formato correcto.



PSU 870 Puntaje Matemáticas

El valor debe inferior o igual a 850

Ilustración 6.1.3: Validación para el valor máximo en los campos de puntajes.



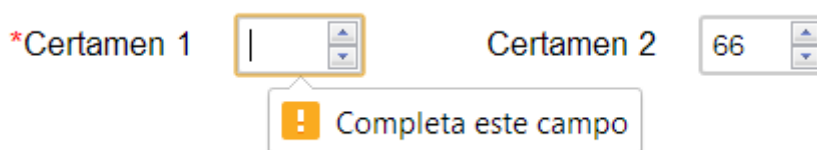
PSU 120 Puntaje Matemáticas

! El valor debe superior o igual a 150

Tipo de Colegio: Parvularia, Primaria, Secundaria

Detailed description: A screenshot of a web form. The 'PSU' field contains the value '120' and is highlighted with a yellow border. A tooltip with a yellow warning icon and the text 'El valor debe superior o igual a 150' points to the field. Below it, there are radio buttons for 'Tipo de Colegio' with options 'Parvularia', 'Primaria', and 'Secundaria'.

Ilustración 6.1.4: Validación para el valor mínimo en PSU.

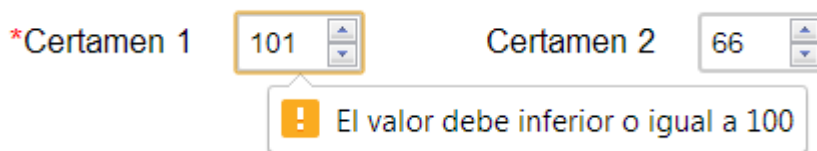


*Certamen 1 Certamen 2 66

! Completa este campo

Detailed description: A screenshot of a form with two input fields. The first field, labeled '*Certamen 1', is empty and highlighted with a yellow border. A tooltip with a yellow warning icon and the text 'Completa este campo' points to it. The second field, labeled 'Certamen 2', contains the value '66'.

Ilustración 6.1.5: Validación campo vacío.



*Certamen 1 101 Certamen 2 66

! El valor debe inferior o igual a 100

Detailed description: A screenshot of a form with two input fields. The first field, labeled '*Certamen 1', contains the value '101' and is highlighted with a yellow border. A tooltip with a yellow warning icon and the text 'El valor debe inferior o igual a 100' points to it. The second field, labeled 'Certamen 2', contains the value '66'.

Ilustración 6.1.6: Validación para el valor máximo en los campos de notas.

También hay que explicar que cuenta con dos botones:



Ilustración 6.1.7: Botones de Borrار y Resultado.

- Un botón para borrar todos los campos del formulario, en caso que se desee realizar esta acción solo basta con presionar el botón donde saldrá el mensaje de dialogo en una ventana emergente, donde hay que confirmar dicha acción. Es primordial tener esto, cuando se tiene un botón de eliminación o de limpieza, ya que por error el usuario puede presionar el botón, sin querer realizarlo. Entonces es importante que muestre el mensaje de confirmación de dicha acción, para estar seguros de lo que se desea.

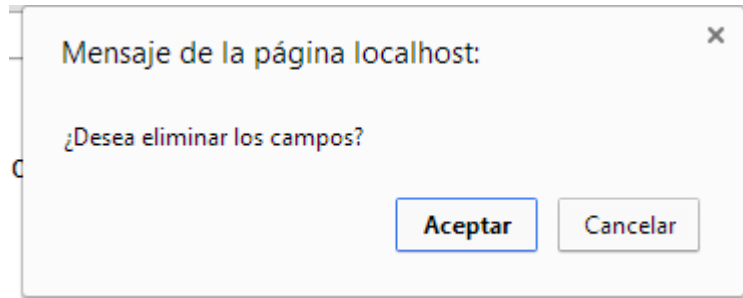


Ilustración 6.1.8: Mensaje de confirmación para borrar todos los campos.

- El otro botón sirve para enviar los resultados mediante el método POST a la otra página donde tenemos el código de PHP incrustado en el HTML (result.php). Es acá donde nos encargamos de recoger los datos y luego analizarlos en las distintas reglas, para finalmente determinar a qué clase corresponde dicho alumno.

Como sabemos puede ser aprobado o reprobado el estudiante, pero si no genera ninguna regla o no encaja en ninguna reglas interesante, no quiere decir que el alumno vaya a reprobado el ramo, significa simplemente que el alumno no genero información contundente o interesante para ser clasificado en alguna de las dos clases.

***i* Según los valores ingresados recientemente :**

El alumno **Francisco Javier Rodríguez Morales** no genera alguna regla o información contundente e interesante.

Ilustración 6.1.9: Mensaje para cuando el alumno no clasifica en ninguna clase.

***i* Según los valores ingresados recientemente :**

El alumno **Francisco Javier Rodríguez Morales** esta propenso a **Aprobar** el curso de programación.

Ilustración 6.1.10: Mensaje para cuando el alumno puede aprobar.

**Según los valores ingresados recientemente :**

El alumno **Francisco Javier Rodríguez Morales** esta propenso a **Reprobar** el curso de programación.

¡ Por favor ponerse en contacto con él a la brevedad !

Ilustración 6.1.11: Mensaje para cuando el alumno puede reprobar.

Sin duda, una aplicación que cumple con lo estipulado en los objetivos específicos, se ha pensado utilizar en beneficio de la gestión del curso y que el profesor o quién la use, le saque el máximo de provecho, todo esto con el propósito de ayudar en el desempeño académico de los estudiantes.

7 CONCLUSION

7.1 Conclusión de acuerdo a los Objetivos Específicos

- **Definir y aplicar un proceso de “Data Mining” a la información relacionada con las calificaciones obtenidas por alumnos en el primer curso de programación de las carreras Ingeniería Civil en Informática e Ingeniería de Ejecución en Computación e Informática:** Para lograr lo propuesto, fue necesario definir y aplicar un proceso de minería de datos, en este proyecto además se integraron las demás fases del proceso KDD, este objetivo específico fue planteado a comienzos del inicio de la tesis con el fin de establecer un proceso que influya de manera positiva en el rendimiento de los estudiantes. Al finalizar este proyecto fue fundamental incorporar y haber ejecutado este proceso de “Data Mining”, para obtener los resultados que se consiguieron.
- **Definir los enfoques y técnicas y herramientas de “Data Mining” más pertinentes a los objetivos establecidos:** Para lograr los resultados esperados, fue necesario definir enfoques, técnicas y herramientas de “Data Mining”, ya que es después de que se toman estas elecciones, que se aplican y se obtienen los distintos modelos a comparar y a analizar. En este caso, se eligieron principalmente los enfoques de clasificación y regresión utilizando las técnicas de reglas de clasificación y árboles de decisión, los algoritmos empleados mediante estas técnicas son: J48, Prism, OneR, entre los más destacados, eficientes y precisos. Hay que mencionar, que la herramienta escogida para trabajar con Minería de Datos fue “WEKA” debido a las razones que se argumentaron en el Capítulo 4.1.
- **Establecer variables que determinen el comportamiento, en términos de la calificación final, de los alumnos del primer curso de programación:** Las variables que se obtuvieron como más influyentes en la nota final del alumno fueron: Carrera, PsuPaa, PuntajeMat, Nota, Colegio, TiempoEntrar, Asistencia, Semestre, Profesor, Certamen1, Certamen2, Certamen3, NotaTest, Trabajo, Examen, TerminoRamo, PrimeraSegunda.

Estas variables determinaron ciertas reglas que han ayudado a concluir cuáles son las que más influyen en el comportamiento del estudiante, respecto a la nota final y sus clases (“Aprobo” y “Reprobo”).

- **Interpretar y demostrar la utilidad del conocimiento obtenido, mediante la construcción de un prototipo que ayude a la gestión del curso:** Después de haber analizado los modelos y haber obtenido buenas conclusiones se procede a la elaboración de un prototipo, en un lenguaje determinado de programación, que le permitirá al profesor, saber que alumnos se encuentran en las clases de “Aprobo” y “Reprobo”, así puede tomar una decisión adecuada respecto a ese alumno.

Todos estos objetivos específicos fueron propuestos y alcanzados al final del proyecto.

7.2 Conclusión personal

Fue necesario un arduo proyecto de investigación pero que a su vez fue muy interesante y novedoso, ya que intenta ayudar en la gestión de los cursos de programación de primer año de las carreras de informática de nuestra Universidad.

Debido al gran crecimiento de la utilización e implementación de esta tecnología (Minería de Datos), al finalizar este proyecto de título me ha dejado satisfecho, ya que se han obtenido buenos resultados y variadas reglas, que tienen que ser utilizadas por el profesor en beneficio del curso y de sus alumnos, además del conocimiento propio que me ha dejado elaborar esta tesis.

El proyecto fue completo ya que se han realizado todas las etapas del proceso KDD en forma metodológica.

Al aplicarse todo lo que conlleva el proceso de Minería de Datos (Elección de Herramienta, enfoques y técnicas) para la búsqueda de patrones, se obtuvo los resultados apropiados para que puedan ser empleados contribuyendo a la educación, al crecimiento y enriquecimiento de la Universidad.

8 BIBLIOGRAFIA

Citas

- [1] MOLINA, Félix. 2002. Data Mining: torturando a los datos hasta que confiesen.
- [2] HERNÁNDEZ-ORALLO, J.; RAMÍREZ-QUINTANA M.J.; FERRI, C. 2004. Introducción a la Minería de Datos. Prentice Hall / Addison-Wesley, Páginas 3 - 7.
- [3] WITTEN, Ian H.; FRANK, Eibe; TRIGG, Len; HALL, Mark; HOLMES, Geoffrey; y CUNNINGHAM, Sally J. WEKA: Practical machine learning tools and techniques with java implementations. Department of Computer Science. University of Waikato. New Zealand. [en línea]. Disponible en:
<<http://www.cs.waikato.ac.nz/~ml/publications/1999/99IHW-EF-LT-MH-GH-SJC%-Tools-Java.pdf>> [consulta: 17 abril 2013].
- [4] CURK, Tomaž; DEMŠAR, Janez; XU, Qikai; LEBAN, Gregor; PETROVIČ, Uroš; Ivan BRATKO, Ivan; SHAULSKY, Gad; ZUPAN, Blaž. 2005. Microarray data mining with visual programming. *Bioinformatics*. Feb 1;21(3):396-8
- [5] NADINIC, Mladen W.; 2008. Data Mining y Data Warehousing, Página 81.

Bibliografía

- FAYYAD, Usama M.; PIATETSKY-SHAPIO, Gregory; SMYTH, Padhraic. *The KDD Process for Extracting Useful Knowledge from Volumes of Data*. COMMUNICATIONS OF THE ACM, 1996, Vol.39, No.11. 27-34p.
- CANIUPÁN Marileo, Mónica A. Proceso data mining y su aplicación en el área docente. Memoria (Ingeniero Civil en Informática). Concepción, Chile. Universidad del Bío-Bío, Depto. de Sistemas de Información, 2000. 233h.

- MÁRQUEZ, Carlos; ROMERO, Cristóbal; VENTURA, Sebastián .Predicción del Fracaso Escolar mediante Técnicas de Minería de Datos. [en línea] of IEEE-RITA Vol. 7, Núm. 3, Nov. 2012. <<http://rita.det.uvigo.es/201208/uploads/IEEE-RITA.2012.V7.N3.A1.pdf>> [consulta: 26 abril 2013].
- INMON, Bill. *Building the Data Warehouse*, 1992.
- HAN, Jiawei; KAMBER, Micheline. *Data Mining: Concepts and Techniques*. USA, The Morgan Kaufmann Publishers, 2001.
- AGRAWAL, Rakesh; IMIELINSKI, Tomasz; SWAMI, Arun. "Database Mining: A Performance Perspective", IEEE Transactions on Knowledge and Data Engineering, Special Issue on Learning and Discovery in Knowledge-Based Databases. Disponible en : <<http://www.almaden.ibm.com/cs/projects/iis/hdb/Publications/papers/tkde93.pdf>> [consulta: 30 mayo 2013].
- PIATETSKY-SHAPIRO, Gregory, Knowledge Discovery in Databases, AAAI/MIT Press, 1996 [en línea] American Association for Artificial Intelligence. <<http://www.kdnuggets.com/gpspubs/aimag-kdd-overview-1996-Fayyad.pdf>> [consulta: 04 junio 2013].
- WITTEN, Ian H. y FRANK, Eibe. *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*, 1999.
- PYLE, Dorian. *Business Modeling and Data Mining*. Morgan Kaufmann, 2003.
- STALLMAN, Richard. GNU Public License. [en línea]. <<http://www.gnu.org/copyleft/gpl.html>> [consulta: 03 mayo 2013].
- FAYYAD, Usama M. Polls: Data mining tools you regularly use. [en línea] <http://www.kdnuggets.com/polls/2002/data_mining_tools.htm> [consulta: 23 junio 2013].

- KNIME 2.1.0 released. [en línea] <<http://www.knime.org/blog/knime-210-released>>. [consulta: 1 julio 2013].
- KEEL, una herramienta de software para el análisis de sistemas. [en línea] <sci2s.ugr.es/publications/ficheros/2010-Derrac-estylf.pdf> [consulta: 4 julio 2013].
- ALCALÁ-FDEZ, J.; SÁNCHEZ, L.; GARCÍA, S.; DEL JESUS, M.J.; VENTURA, S.; GARREL, J.M.; OTERO, J.; ROMERO, C.; BACARIT, J.; RIVAS, V.M.; FERNANDEZ, J.C.; HERRERA, F. "KEEL: A Software Tool to Assess Evolutionary Algorithms to Data Mining Problems", *Soft Computing* 13:3 (2009) 307-318. [en línea] <<http://sci2s.ugr.es/keel/pdf/keel/articulo/Alcalaetal-SoftComputing-Keel1.0.pdf>> [consulta: 3 julio 2013].
- R Development Core Team R: A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria. 2005. [en línea] <<http://www.R-project.org>> [consulta: 2 julio 2013]
- PALMER, A. y MONTAÑO, J. J. ¿Qué son las redes neuronales artificiales? Aplicaciones realizadas en el ámbito de las adicciones. 11, 243-255. 1999.
- BIGUS, J.P. Data mining with neural networks: solving business problems from application development to decision support. New York: McGraw-Hill. 1996
- IZAURIETA, Fernando y SAAVEDRA, Carlos. Redes neuronales artificiales, Universidad de Concepción de Chile.
- MATICH, Damián. Redes Neuronales: Conceptos Básicos y Aplicaciones. [en línea] <<ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/match-redesneuronales.pdf>> [consulta: 10 julio 2013].
- SORIA, Emilio y BLANCO, Antonio, "Redes Neuronales Artificiales".

ANEXOS

ANEXO 1: Glosario de Términos

- **Data archeology** Se refiere al arte y la ciencia de la recuperación de datos informáticos codificados y / o cifrados en medios o formatos ya obsoletos. Arqueología de datos también puede referirse a la recuperación de la información de los formatos electrónicos dañados después de catástrofes naturales o de origen humano.
- **SQL** Es un lenguaje declarativo de acceso a bases de datos relacionales que permite especificar diversos tipos de operaciones en ellas.
- **Gygabytes** Es una unidad de almacenamiento de información cuyo símbolo es el GB; equivale a 10^9 byte.
- **Inteligencia artificial** La Inteligencia Artificial es una combinación de la ciencia del computador, fisiología y filosofía, tan general y amplio como eso, es que reúne varios campos, todos los cuales tienen en común la creación de máquinas que pueden pensar.
- **Estadística** Es una ciencia formal que estudia la recolección, análisis e interpretación de datos de una muestra representativa, ya sea para ayudar en la toma de decisiones o para explicar condiciones regulares o irregulares de algún fenómeno

- **Aprendizaje automático** Es una rama de la Inteligencia Artificial cuyo objetivo es desarrollar técnicas que permitan a las computadoras aprender
- **TCL/TK** Es un lenguaje de script que se utiliza principalmente para el desarrollo rápido de prototipos, aplicaciones "script", interfaces gráficas y pruebas. La combinación de Tcl con Tk (del inglés Tool Kit) es conocida como TCL/TK, y se utiliza para la creación de interfaces gráficas.
- **Eclipse** Es un programa informático compuesto por un conjunto de herramientas de programación de código abierto multiplataforma
- **Python** Se trata de un lenguaje de programación multiparadigma, ya que soporta orientación a objetos, programación imperativa y, en menor medida, programación funcional. Además es un lenguaje interpretado, usa tipado dinámico y es multiplataforma.
- **MS-DOS** Es un sistema operativo para computadores basados en la arquitectura x86.
- **XML** Es un lenguaje de marcas, utilizado para almacenar datos en forma legible.

ANEXO 2: Resultados algoritmo J48

Este algoritmo fue el que más precisión obtuvo en la comparación de la validación cruzada utilizando todos los atributos y considerando el costo de clasificación. Se puede observar la matriz de costo, y la matriz de confusión, además de la precisión total y del árbol que genera.

=== Run information ===

```
Scheme:weka.classifiers.meta.CostSensitiveClassifier -cost-matrix "[0.0 1.0; 1.5 0.0]" -S 1  
-W weka.classifiers.trees.J48 -- -C 0.25 -M 2
```

```
Relation:          ExcelFinal_CSV      -   aprobo_reprobo   con   comas-  
weka.filters.unsupervised.attribute.Remove-R1
```

```
Instances:  511
```

```
Attributes:  19
```

Carrera

PsuPaa

PuntajeMat

Nota

Colegio

TiempoEntrar

Asistencia

Semestre

Profesor

Certamen1

Certamen2

Certamen3

NotaTest

Trabajo

NotaPresentacion

Examen

NotaFinal

TerminoRamo

PrimeraSegunda

Test mode:10-fold cross-validation

=== Classifier model (full training set) ===

CostSensitiveClassifier using reweighted training instances

weka.classifiers.trees.J48 -C 0.25 -M 2

Classifier Model

J48 pruned tree

NotaPresentacion = Regular: Aprobo (90.36)

NotaPresentacion = Mal

| Examen = NoRinde: Reprobo (26.39)

| Examen = MuyMal: Reprobo (29.59/3.2)

| Examen = Mal: Reprobo (14.79/4.0)

| Examen = Regular

| | TiempoEntrar = Mucho: Reprobo (2.4)

| | TiempoEntrar = Normal: Aprobo (8.4/1.2)

| | TiempoEntrar = Excesivo: Aprobo (0.0)

| Examen = Bien: Aprobo (3.2)

| Examen = MuyBien: Reprobo (3.6)

NotaPresentacion = MuyMal: Reprobo (210.32/4.0)

NotaPresentacion = NoCumpleRequisitos: Reprobo (17.99)

NotaPresentacion = SinNota: Reprobo (12.0)

NotaPresentacion = Bien: Aprobo (79.97)

NotaPresentacion = MuyBien: Aprobo (12.0)

Number of Leaves : 14

Size of the tree : 17

Cost Matrix

```
0 1
1.5 0
```

Time taken to build model: 0 seconds

=== Stratified cross-validation ===

=== Summary ===

```
Correctly Classified Instances    488      95.499 %
Incorrectly Classified Instances   23      4.501 %
Kappa statistic                   0.91
Mean absolute error               0.0569
Root mean squared error           0.1928
Relative absolute error           11.3884 %
Root relative squared error       38.5615 %
Total Number of Instances        511
```

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	0.929	0.02	0.979	0.929	0.954	0.98	Aprobo
	0.98	0.071	0.933	0.98	0.956	0.98	Reprobo
Weighted Avg.	0.955	0.045	0.956	0.955	0.955	0.98	

=== Confusion Matrix ===

```
a b <-- classified as
237 18 | a = Aprobo
5 251 | b = Reprobo
```

ANEXO 3: Archivo Utilizado en Minería de Datos

Se han ocultados las variables de Nombre y Rut del alumno, con el fin de mantener la privacidad de los datos y de los mismos alumnos.

Los atributos a considerar son:

- Carrera
- PsuPaa
- PuntajeMat
- Nota
- Colegio
- TiempoEntrar
- Asistencia
- Semestre
- Profesor
- Certamen1
- Certamen2
- Certamen3
- NotaTest
- Trabajo
- NotaPresentacion
- Examen
- NotaFinal
- TerminoRamo
- PrimeraSegunda

Francisco Rodríguez Morales | 119
Habilitación Profesional

ID	Carrera	Psu Paa	Punta jeMat	Nota	Colegio	TiempoEntrar	Asistencia	Semestre	Profesor	Certamen1	Certamen2	Certamen3	NotaTest	Trabajo	NotaPresentacion	Examen	NotaFinal	TerminoRamo	Primera Segunda
1	ICL	Regular	Regular	Muy Bien	Subvencionado	Mucho	SinInformacion	PrimerSem	MC	Mal	Regular	NoAplica	Muy Mal	Muy Bien	Regular	NoRinde	Aprobo	SI	Primera
2	ICL	Regular	Regular	Bien	Municipal	Normal	Muy Buena	PrimerSem	MC	Bien	Muy Mal	Muy Mal	Regular	Bien	Mal	NoRinde	Reprobo	SI	Primera
3	ICL	Regular	Regular	Muy Bien	Municipal	Normal	Buena	SinInformacion	MC	Muy Mal	Muy Mal	NoAplica	Muy Mal	Regular	Muy Mal	NoRinde	Reprobo	SI	Primera
4	ICL	Regular	Regular	Muy Bien	Municipal	Normal	Muy Buena	SinInformacion	MC	Muy Mal	Muy Mal	NoAplica	Mal	Bien	Muy Mal	NoRinde	Reprobo	SI	Primera
5	IEC	Regular	Regular	Muy Bien	Municipal	Normal	SinInformacion	SegundoSem	CV	Muy Mal	Muy Mal	NoAplica	Muy Mal	Muy Mal	Muy Mal	NoRinde	Reprobo	NO	Segunda
6	ICL	Regular	Regular	Bien	Subvencionado	Normal	Buena	PrimerSem	MC	Muy Bien	Mal	Regular	Bien	Muy Mal	Regular	NoRinde	Aprobo	SI	Segunda
7	IEC	Bueno	Bueno	Bien	ParticularPag	Mucho	SinInformacion	SegundoSem	CV	Muy Mal	Muy Mal	NoAplica	Mal	Muy Mal	Muy Mal	NoRinde	Reprobo	NO	Segunda
8	IEC	Regular	Regular	Muy Bien	Municipal	Normal	SinInformacion	PrimerSem	CV	Mal	Muy Mal	Muy Mal	Muy Mal	Bien	Muy Mal	Muy Mal	Reprobo	SI	Primera
9	IEC	Regular	Regular	Muy Bien	Municipal	Mucho	Baja	PrimerSem	MC	Muy Mal	NoRinde	NoAplica	Muy Mal	NoRinde	NoCumpleRequisitos	NoRinde	Reprobo	NO	Primera
10	ICL	Reg	Regul	Bien	Municipal	Normal	SinInformacion	PrimerSem	MC	Bien	NoRinde	NoAplica	Muy	NoRinde	SinNot	NoRinde	Reprobo	NO	Primera

Francisco Rodríguez Morales | 120
Habilitación Profesional

	C	ular	ar		pal	I	macion	em			nde	lica	Mal	de	a	de			
11	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
12	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyBi en	MuyM al	NoRin de	Reprobo	SI	Primera
13	I E C I	Bue no	MuyB ueno	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Segunda
14	I C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
15	I E C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma I	SinInfor macion	SinInfor macion	CV	Regul ar	Mal	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
16	I E C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	MuyBu ena	PrimerS em	MC	Muy Mal	Regul ar	Muy Mal	Bien	Bien	Mal	Mal	Reprobo	SI	Primera
17	I E C I	Bue no	Buen o	Muy Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Bien	MuyB ien	NoAp lica	Reg ular	Mal	Bien	NoRin de	Aprobo	SI	Primera
18	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	SinInfor macion	PrimerS em	MC	Regul ar	Mal	NoAp lica	Reg ular	Mal	Regul ar	NoRin de	Aprobo	SI	Primera
19	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	MuyB ien	Regul ar	NoAp lica	Reg ular	Bien	Bien	NoRin de	Aprobo	SI	Primera
20	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	SinInfor macion	SinInfor macion	CV	Mal	MuyB ien	NoAp lica	Bien	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
21	I	Reg	Regul	Bien	Particul	Mucho	SinInfor	Segund	CV	Mal	Muy	NoAp	Bien	MuyBi	Mal	Mal	Reprobo	SI	Segunda

Francisco Rodríguez Morales | 121
Habilitación Profesional

	E C I	ular	ar		arPag		macion	oSem			Mal	lica		en					
22	I C I	Reg ular	Buen o	Bien	Munici pal	Mucho	Buena	SinInfor macion	MC	Bien	Mal	NoAp lica	Reg ular	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
23	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Muy Mal	Mal	MuyM al	Muy Mal	Reprobo	SI	Primera
24	I C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	Regul ar	MuyB ien	NoAp lica	Mal	MuyM al	Mal	NoRin de	Reprobo	SI	Primera
25	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
26	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Mal	Bien	Bien	Bien	MuyM al	Bien	NoRin de	Aprobo	SI	Primera
27	I E C I	Reg ular	Buen o	Bien	Particul arPag	Norma l	SinInfor macion	PrimerS em	CV	Mal	NoRi nde	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
28	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Mal	Mal	Muy Mal	Reg ular	MuyM al	MuyM al	NoRin de	Reprobo	SI	Segunda
29	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	Regul ar	Muy Mal	NoAp lica	Muy Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
30	I C I	Reg ular	Regul ar	Bien	Subven cionado	Excesiv o	MuyBu ena	PrimerS em	MC	MuyB ien	MuyB ien	Bien	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
31	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Mal	Mal	Muy Mal	Bien	Bien	Mal	Regul ar	Aprobo	SI	Primera
32	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Mal	NoAp lica	Reg ular	Bien	Regul ar	NoRin de	Aprobo	SI	Primera

Francisco Rodríguez Morales | 122
Habilitación Profesional

	I																		
33	IEC	Regular	Regular	Muy Bien	Subvencionado	Norma	SinInformacion	SinInformacion	CV	Mal	Muy Mal	NoAplica	Mal	Regular	MuyMal	NoRinde	Reprobo	SI	Primera
34	IC	Regular	Regular	Bien	Subvencionado	Mucho	SinInformacion	PrimerSem	CV	Muy Mal	Muy Mal	NoAplica	Muy Mal	Bien	MuyMal	NoRinde	Reprobo	NO	Primera
35	IEC	Regular	Bueno	Muy Bien	Municipal	Mucho	SinInformacion	SinInformacion	CV	Muy Mal	Muy Mal	NoAplica	Regular	Mal	MuyMal	Bien	Aprobo	SI	Primera
36	IC	Regular	Regular	Bien	Subvencionado	Norma	SinInformacion	PrimerSem	MC	Regular	MuyBien	NoAplica	Bien	Mal	Regular	NoRinde	Aprobo	SI	Primera
37	IC	Regular	Regular	Bien	ParticularPag	Mucho	Buena	PrimerSem	MC	MuyBien	Regular	Regular	Mal	MuyMal	Regular	NoRinde	Aprobo	SI	Primera
38	IC	Regular	Regular	Bien	Municipal	Norma	SinInformacion	PrimerSem	MC	Regular	Muy Mal	NoAplica	Mal	MuyBien	Regular	NoRinde	Aprobo	SI	Primera
39	IC	Regular	Bueno	Bien	Subvencionado	Norma	MuyBuena	PrimerSem	MC	Regular	MuyBien	Regular	Muy Bien	MuyBien	Bien	NoRinde	Aprobo	SI	Primera
40	IEC	Regular	Regular	Bien	Municipal	Mucho	SinInformacion	PrimerSem	MC	Regular	Bien	NoAplica	Bien	MuyBien	Bien	NoRinde	Aprobo	SI	Primera
41	IC	Regular	Regular	Muy Bien	Municipal	Norma	MuyBuena	PrimerSem	MC	Bien	Muy Mal	Muy Mal	Mal	Mal	Mal	NoRinde	Reprobo	SI	Primera
42	IC	Regular	Regular	Bien	Municipal	Norma	Baja	SinInformacion	MC	Muy Mal	NoRinde	NoAplica	Muy Mal	NoRinde	MuyMal	NoRinde	Reprobo	NO	Primera
43	IEC	Regular	Regular	Bien	Subvencionado	Mucho	SinInformacion	SegundoSem	CV	MuyBien	Regular	NoAplica	Bien	MuyBien	Bien	NoRinde	Aprobo	SI	Segunda
44	I	Reg	Regul	Muy	Municipi	Norma	MuyBu	PrimerS	MC	Bien	Mal	Regul	Bien	MuyBi	Bien	NoRin	Aprobo	SI	Primera

Francisco Rodríguez Morales | 123
Habilitación Profesional

	C	ular	ar	Bien	pal	I	ena	em				ar		en		de			
45	I	Reg	Regul	Bien	Munici	Norma	Buena	SinInfor	MC	MuyB	Muy	NoAp	Muy	Bien	Mal	Mal	Reprobo	SI	Primera
46	E	Reg	Regul	Muy	Munici	Mucho	Regular	PrimerS	MC	Muy	NoRi	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	NO	Primera
47	I	Reg	Regul	Bien	Munici	Norma	Buena	PrimerS	MC	Bien	Regul	Bien	Bien	Bien	Bien	NoRin	Aprobo	SI	Primera
48	E	Reg	Buen	Bien	Munici	Norma	SinInfor	Segund	CV	Muy	Muy	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	NO	Segunda
49	E	Bue	Buen	Bien	Subven	Mucho	SinInfor	Segund	CV	Muy	Muy	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	NO	Segunda
50	I	Reg	Regul	Bien	Munici	Norma	SinInfor	PrimerS	MC	Muy	Muy	NoAp	Reg	NoRin	MuyM	NoRin	Reprobo	NO	Primera
51	E	Bue	Buen	Bien	Munici	Norma	SinInfor	SinInfor	CV	Muy	Muy	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	NO	Primera
52	I	Reg	Buen	Bien	Munici	Norma	SinInfor	Segund	CV	Bien	Regul	NoAp	Mal	MuyBi	Regul	NoRin	Aprobo	SI	Segunda
53	I	Reg	Regul	Muy	Munici	Norma	SinInfor	PrimerS	MC	Muy	Muy	NoAp	Mal	MuyBi	Mal	NoRin	Reprobo	SI	Segunda
54	E	Reg	Buen	Bien	Subven	Mucho	SinInfor	SinInfor	CV	Mal	Muy	NoAp	Mal	MuyM	MuyM	Muy	Reprobo	SI	Primera

Francisco Rodríguez Morales | 124
Habilitación Profesional

55	I C	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Regul ar	Mal	NoAp lica	Reg ular	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
56	I E C I	Reg ular	Buen o	Reg ular	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
57	I C	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Bien	MuyB ien	MuyB ien	Muy Bien	Bien	MuyBi en	NoRin de	Aprobo	SI	Primera
58	I C	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	MuyB ien	Bien	MuyB ien	NoRi nde	MuyBi en	MuyBi en	NoRin de	Aprobo	SI	Primera
59	I C	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	MuyBaj a	PrimerS em	MC	NoRi nde	NoRi nde	NoAp lica	Muy Mal	NoRin de	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Segunda
60	I C	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	MuyB ien	MuyB ien	Bien	Bien	Regula r	Bien	NoRin de	Aprobo	SI	Segunda
61	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Mal	Regul ar	NoAp lica	Muy Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
62	I E C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	MuyB ien	Regul ar	NoAp lica	Reg ular	Bien	Bien	NoRin de	Aprobo	SI	Primera
63	I E C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Muy Mal	Mal	NoAp lica	Muy Bien	MuyBi en	Mal	Mal	Aprobo	SI	Segunda
64	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Muy Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera
65	I C	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Bien	Mal	NoAp lica	Muy Mal	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera

Francisco Rodríguez Morales | 125
Habilitación Profesional

66	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Mal	MuyB ien	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
67	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	SinInfor macion	MC	MuyB ien	NoRi nde	NoAp lica	Bien	Bien	MuyBi en	NoRin de	Aprobo	SI	Primera
68	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	MuyBu ena	SinInfor macion	MC	MuyB ien	Bien	NoAp lica	Reg ular	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
69	I E C I	Reg ular	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Bien	MuyB ien	NoAp lica	Muy Mal	Bien	Bien	NoRin de	Aprobo	SI	Primera
70	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	Regul ar	Muy Mal	NoAp lica	Mal	Mal	Mal	NoRin de	Reprobo	SI	Primera
71	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Mucho	Buena	PrimerS em	MC	Muy Mal	MuyB ien	Mal	Reg ular	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
72	I C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma l	MuyBu ena	SinInfor macion	MC	MuyB ien	MuyB ien	NoAp lica	Muy Bien	MuyBi en	MuyBi en	NoRin de	Aprobo	SI	Primera
73	I C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Bien	NoRin de	Mal	Muy Mal	Reprobo	SI	Primera
74	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	Bien	Bien	NoAp lica	Mal	Bien	Bien	NoRin de	Aprobo	SI	Primera
75	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Bien	Bien	NoAp lica	Bien	Bien	Bien	NoRin de	Aprobo	SI	Segunda
76	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Mal	NoRi nde	Muy Mal	Bien	Bien	MuyM al	Mal	Reprobo	SI	Primera
77	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	MuyB ien	Bien	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
78	I	Reg	Regul	Bien	Munici	Norma	Justifica	PrimerS	MC	Muy	NoRi	Muy	Bien	Bien	MuyM	NoRin	Reprobo	SI	Primera

Francisco Rodríguez Morales | 126
Habilitación Profesional

	C	ular	ar		pal	I	do	em		Mal	nde	Mal			al	de				
79	I	Regu	Regu	Bien	Munici	Norma	SinInfor	PrimerS	MC	Bien	Mal	NoAp	Regu	MuyBi	Bien	NoRin	Aprobo	SI	Primera	
80	I	Regu	Regu	Muy	Subven	Norma	MuyBu	PrimerS	MC	MuyB	Mal	Bien	Bien	MuyM	Regul	NoRin	Aprobo	SI	Primera	
81	I	Regu	Regu	Muy	Munici	Norma	Buena	PrimerS	MC	Mal	Muy	Muy	Mal	Mal	MuyM	NoRin	Reprobo	SI	Primera	
82	I	Regu	Regu	Muy	Munici	Norma	Buena	PrimerS	MC	Muy	Muy	NoAp	Regu	Bien	MuyM	Muy	Mal	Reprobo	SI	Primera
83	I	Regu	Regu	Bien	Munici	Norma	SinInfor	PrimerS	CV	Regul	Muy	Muy	Muy	MuyBi	Regul	NoRin	Aprobo	SI	Primera	
84	I	Regu	Regu	Bien	Subven	Norma	MuyBu	PrimerS	MC	MuyB	Muy	Muy	Regu	Mal	MuyM	NoRin	Reprobo	SI	Primera	
85	I	Regu	Regu	Muy	Munici	Norma	SinInfor	PrimerS	CV	Muy	Mal	Regul	Regu	MuyBi	Bien	NoRin	Aprobo	SI	Primera	
86	I	Regu	Regu	Bien	Munici		SinInfor	PrimerS	CV	Muy	Muy	Muy	Muy	Mal	MuyM	NoRin	Reprobo	SI	Primera	
87	I	Regu	Regu	Bien	Munici	Norma	SinInfor	SinInfor	CV	Mal	Muy	NoAp	Mal	Mal	Mal	Muy	Mal	Reprobo	SI	Primera
88	I	Regu	Regu	Bien	Munici	Norma	MuyBu	PrimerS	MC	Bien	Mal	Regul	Regu	MuyM	Regul	NoRin	Aprobo	SI	Primera	
89	I	Regu	Regu	Muy	Munici	Norma	MuyBaj	SinInfor	MC	NoRi	NoRi	NoAp	NoRi	NoRin	SinNot	NoRin	Reprobo	NO	Primera	

Francisco Rodríguez Morales | 127
Habilitación Profesional

90	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera
91	I E C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Segunda
92	I C I	Reg ular	Buen o	Muy Bien	Subven cionado	Mucho	SinInfor macion	Segund oSem	CV	MuyB ien	Regul ar	MuyB ien	NoRi nde	MuyBi en	MuyBi en	NoRin de	Aprobo	SI	Primera
93	I C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	MuyBu ena	PrimerS em	MC	Mal	Mal	Regul ar	Regul ar	Mal	Regul ar	NoRin de	Aprobo	SI	Primera
94	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	Bien	Bien	Bien	Mal	Bien	NoRin de	Aprobo	SI	Primera
95	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Mal	Muy Mal	Muy Mal	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
96	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Bien	Bien	NoAp lica	Regul ar	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
97	I C I	Reg ular	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Mal	Bien	NoAp lica	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
98	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Bien	Mal	Bien	Bien	MuyM al	Regul ar	NoRin de	Aprobo	SI	Primera
99	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Regular	PrimerS em	MC	MuyB ien	Bien	Regul ar	Muy Mal	Mal	Regul ar	NoRin de	Aprobo	SI	Primera
100	I E C I	Reg ular	Bajo	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	MuyBi en	MuyM al	Muy Mal	Reprobo	SI	Primera
101	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	Regul ar	Aprobo	SI	Primera

Francisco Rodríguez Morales | 128
Habilitación Profesional

	C																		
102	I E C I	Bue no	Buen o	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Muy Bien	Regula r	MuyM al	Mal	Reprobo	SI	Segunda
103	I C I	Regu lar	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Mal	Mal	Mal	Bien	Bien	Mal	NoRin de	Reprobo	SI	Primera
104	I E C I	Regu lar	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	SI	Primera
105	I E C I	Regu lar	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Mal	Mal	NoAp lica	Mal	MuyBi en	Mal	MuyBi en	Reprobo	SI	Primera
106	I C I	Regu lar	Regul ar	Muy Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	MuyB ien	Mal	NoAp lica	Muy Mal	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
107	I E C I	Regu lar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Mal	NoAp lica	Bien	MuyBi en	Mal	Muy Mal	Aprobo	SI	Primera
108	I E C I	Regu lar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Mal	Mal	NoAp lica	Muy Mal	Bien	Mal	Mal	Reprobo	SI	Primera
109	I C I	Regu lar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Bien	Bien	NoAp lica	Bien	Regula r	Bien	NoRin de	Aprobo	SI	Primera
110	I C I	Regu lar	Regul ar	Bien	Subven cionado	Norma l	Buena	SinInfor macion	MC	Regul ar	NoRi nde	NoAp lica	Regu lar	Bien	Mal	Regul ar	Reprobo	SI	Primera
111	I C I	Regu lar	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	MuyB ien	Regul ar	NoAp lica	Muy Mal	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
112	I E	Regu lar	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Mal	Mal	Regu lar	Bien	Regul ar	NoRin de	Aprobo	SI	Primera

Francisco Rodríguez Morales | 129
Habilitación Profesional

	C																		
113	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	Bien	Bien	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
114	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	Muy Mal	Reprobo	SI	Primera
115	I E C I	Reg ular	Buen o	Bien	Subven cionado	Mucho	Buena	PrimerS em	MC	Bien	Regul ar	Muy Mal	Muy Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
116	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Regul ar	Mal	NoAp lica	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
117	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBaj a	SinInfor macion	MC	NoRi nde	NoRi nde	NoAp lica	NoRi nde	NoRin de	SinNot a	NoRin de	Reprobo	NO	Primera
118	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	Buena	PrimerS em	MC	Muy Mal	Muy Mal	Muy Mal	Bien	MuyBi en	Mal	NoRin de	Reprobo	SI	Primera
119	I E C I	Reg ular	Buen o	Bien	Particul arPag	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Mal	NoAp lica	Muy Mal	Bien	MuyM al	Muy Mal	Reprobo	SI	Primera
120	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Muy Mal	Muy Mal	Muy Mal	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
121	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
122	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Excesiv o	SinInfor macion	PrimerS em	MC	Bien	Muy Mal	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
123	I	Reg	Regul	Muy	Munici	Norma	SinInfor	PrimerS	MC	Muy	Muy	NoAp	Reg	MuyBi	MuyM	Muy	Aprobo	SI	Primera

Francisco Rodríguez Morales | 130
Habilitación Profesional

	E C I	ular	ar	Bien	pal	I	macion	em		Mal	Mal	lica	ular	en	al	Mal			
124	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	SinInfor macion	PrimerS em	MC	Mal	Mal	NoAp lica	Mal	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
125	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	SinInfor macion	PrimerS em	MC	Muy Mal	Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
126	I E C I	Bue no	Buen o	Reg ular	Subven cionado	Norma I	Buena	PrimerS em	MC	Mal	Bien	Mal	Muy Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
127	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	SinInfor macion	PrimerS em	MC	Mal	Bien	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
128	I C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
129	I E C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	MuyB ien	Muy Mal	NoAp lica	Muy Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Segunda
130	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma I	SinInfor macion	Segund oSem	CV	Mal	Mal	NoAp lica	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Segunda
131	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	Buena	SinInfor macion	MC	Regul ar	Muy Mal	NoAp lica	Muy Mal	MuyBi en	Mal	NoRin de	Reprobo	SI	Primera
132	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	Buena	PrimerS em	MC	Bien	Bien	Bien	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
133	I E C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Muy Mal	Bien	Mal	Regul ar	Reprobo	SI	Primera

Francisco Rodríguez Morales | 131
Habilitación Profesional

134	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Bien	Muy Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
135	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Buena	SinInfor macion	MC	Regul ar	Regul ar	NoAp lica	Reg ular	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
136	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	Buena	PrimerS em	MC	Bien	Regul ar	Bien	Bien	MuyM al	Regul ar	NoRin de	Aprobo	SI	Primera
137	I E C I	Reg ular	Regul ar	Bien	Munici pal	Excesiv o	Regular	PrimerS em	MC	Muy Mal	Muy Mal	Muy Mal	Reg ular	Mal	NoCu mpleR equisi tos	NoRin de	Reprobo	SI	Segunda
138	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	Muy Mal	Reprobo	SI	Segunda
139	I C I	Bue no	Buen o	Muy Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Bien	MuyB ien	Mal	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
140	I C I	Reg ular	Regul ar	Bien	Particul arPag	Norma l	MuyBu ena	SinInfor macion	MC	Bien	Mal	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
141	I E C I	Bue no	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
142	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	Bien	Muy Mal	NoAp lica	Mal	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
143	I E C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
144	I C I	Reg ular	Regul ar	Bien	Particul arPag	Norma l	Buena	PrimerS em	MC	Bien	Muy Mal	Muy Mal	Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera

Francisco Rodríguez Morales | 132
Habilitación Profesional

145	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Bien	Bien	Mal	Mal	Aprobo	SI	Primera
146	I C I	Reg ular	Regul ar	Bien	Particul arPag	Norma l	Buena	PrimerS em	MC	Bien	Muy Mal	Mal	Reg ular	MuyM al	Mal	NoRin de	Reprobo	SI	Primera
147	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	NoRin de	MuyM al	NoRin de	Reprobo	SI	Primera
148	I E C I	Bue no	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	Bien	Regul ar	NoAp lica	Muy Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Segunda
149	I C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	Baja	SinInfor macion	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
150	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Buena	SinInfor macion	MC	Muy Mal	Muy Mal	NoAp lica	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
151	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	SinInfor macion	MC	Bien	Muy Mal	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
152	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	NO	Primera
153	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	NoRi nde	NoRi nde	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
154	I E C I	Reg ular	Regul ar	Bien	Particul arPag	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	Mal	Mal	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
155	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera
156	I	Reg	Regul	Muy	Munici	Norma	Buena	SinInfor	MC	Muy	Muy	NoAp	Muy	Bien	MuyM	NoRin	Reprobo	SI	Primera

Francisco Rodríguez Morales | 133
Habilitación Profesional

	C	ular	ar	Bien	pal	I		macion		Mal	Mal	lica	Mal		al	de			
157	I E C I	Reg ular	Buen o	Muy Bien	Subven cionado	Norma I	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Reg ular	Bien	Mal	Muy Mal	Aprobo	SI	Primera
158	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	MuyBu ena	PrimerS em	MC	Bien	Muy Mal	Muy Mal	Reg ular	Bien	Mal	NoRin de	Reprobo	SI	Primera
159	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	Buena	PrimerS em	MC	Mal	Mal	Bien	Bien	MuyM al	Regul ar	NoRin de	Aprobo	SI	Primera
160	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	SinInfor macion	PrimerS em	MC	MuyB ien	MuyB ien	NoAp lica	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
161	I E C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma I	SinInfor macion	Segund oSem	CV	MuyB ien	Regul ar	NoAp lica	Bien	Regula r	Bien	NoRin de	Aprobo	SI	Segunda
162	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	MuyBu ena	PrimerS em	MC	MuyB ien	Bien	Bien	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
163	I E C I	Bue no	Regul ar	Bien	Munici pal	Norma I	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
164	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	Muy Mal	Mal	MuyBi en	Mal	Muy Mal	Reprobo	SI	Primera
165	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	MuyBu ena	PrimerS em	MC	MuyB ien	MuyB ien	Bien	Bien	MuyM al	Bien	NoRin de	Aprobo	SI	Primera
166	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	SinInfor macion	PrimerS em	MC	NoRi nde	NoRi nde	NoAp lica	Mal	NoRin de	SinNot a	NoRin de	Reprobo	NO	Primera
167	I	Reg	Regul	Muy	Munici	Norma	SinInfor	PrimerS	MC	Mal	Muy	NoAp	Mal	NoRin	MuyM	NoRin	Reprobo	SI	Primera

Francisco Rodríguez Morales | 134
Habilitación Profesional

	E C I	ular	ar	Bien	pal	I	macion	em			Mal	lica		de	al	de			
168	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Regul ar	Regul ar	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
169	I E C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	MuyB ien	Muy Mal	NoAp lica	Reg ular	Regula r	Regul ar	NoRin de	Aprobo	SI	Primera
170	I E C I	Reg ular	Regul ar	Reg ular	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Bien	Bien	Regul ar	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
171	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	NoRi nde	NoAp lica	Muy Mal	Mal	MuyM al	NoRin de	Reprobo	NO	Primera
172	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	Regul ar	Mal	NoAp lica	Muy Mal	Regula r	Regul ar	NoRin de	Aprobo	SI	Primera
173	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Muy Mal	MuyBi en	MuyM al	NoRin de	Reprobo	SI	Primera
174	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Reg ular	Bien	MuyM al	Bien	Reprobo	SI	Primera
175	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Muy Mal	Mal	Muy Mal	Mal	MuyBi en	Mal	Bien	Aprobo	SI	Segunda
176	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Reg ular	MuyM al	Mal	Muy Mal	Reprobo	SI	Primera
177	I	Reg	Regul	Bien	Subven	Norma	Buena	SinInfor	MC	MuyB	Bien	NoAp	Reg	Regula	Bien	NoRin	Aprobo	SI	Primera

Francisco Rodríguez Morales | 135
Habilitación Profesional

	C	ular	ar		cionado	l		macion		ien		lica	ular	r		de			
178	I E C I	Reg ular	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
179	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	Bien	Bien	NoAp lica	Reg ular	Bien	Bien	NoRin de	Aprobo	SI	Primera
180	I C I	Reg ular	Regul ar	Reg ular	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	Regul ar	Regul ar	Muy Mal	NoRi nde	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
181	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	MuyB ien	Mal	Muy Mal	Reg ular	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
182	I E C I	Reg ular	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Reg ular	MuyBi en	MuyM al	NoRin de	Reprobo	SI	Primera
183	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	Buena	SinInfor macion	MC	MuyB ien	Bien	NoAp lica	Reg ular	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
184	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Bien	Muy Mal	Mal	Reg ular	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
185	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
186	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Bien	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
187	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Buena	SinInfor macion	MC	Regul ar	MuyB ien	NoAp lica	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
188	I	Reg	Regul	Bien	Munici	Norma	SinInfor	SinInfor	CV	Muy	Muy	NoAp	Mal	Mal	MuyM	Muy	Reprobo	SI	Primera

Francisco Rodríguez Morales | 136
Habilitación Profesional

	E C I	ular	ar		pal	I	macion	macion		Mal	Mal	lica			al	Mal			
189	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Reg ular	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
190	I E C I	Reg ular	Regul ar	Bien	Particul arPag	Excesiv o	SinInfor macion	PrimerS em	CV	Mal	NoRi nde	NoAp lica	Muy Bien	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
191	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Muy Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera
192	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	MuyB ien	Muy Mal	Bien	Mal	MuyM al	Mal	NoRin de	Reprobo	SI	Primera
193	I C I	Reg ular	Buen o	Bien	Subven cionado	Norma l	MuyBu ena	SinInfor macion	MC	Regul ar	Mal	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
194	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Mucho	Baja	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Mal	NoRin de	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
195	I E C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
196	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Bien	NoAp lica	Reg ular	NoRin de	Bien	NoRin de	Aprobo	SI	Segunda
197	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	CV	NoRi nde	NoRi nde	NoAp lica	Muy Bien	NoRin de	SinNot a	NoRin de	Reprobo	NO	Primera
198	I E	Bue no	Buen o	Muy Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Regul ar	Bien	NoAp lica	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Segunda

Francisco Rodríguez Morales | 137
Habilitación Profesional

	C																		
199	I E C I	Bue no	Buen o	Muy Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Regul ar	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
200	I C I	Regul ar	Regul ar	Muy Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
201	I E C I	Regul ar	Buen o	Muy Bien	Subven cionado	Mucho	Buena	PrimerS em	MC	Muy Mal	Bien	Mal	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
202	I E C I	Regul ar	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
203	I E C I	Regul ar	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	MuyB ien	Muy Mal	NoAp lica	Mal	Bien	Mal	Muy Mal	Aprobo	SI	Primera
204	I E C I	Regul ar	Buen o	Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Mal	Muy Mal	Muy Mal	Bien	NoRin de	MuyM al	NoRin de	Reprobo	SI	Primera
205	I E C I	Regul ar	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Regul ar	MuyBi en	MuyM al	NoRin de	Reprobo	SI	Primera
206	I C I	Regul ar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Mal	MuyBi en	MuyM al	NoRin de	Reprobo	SI	Primera
207	I E C I	Regul ar	Regul ar	Bien	Munici pal	Excesiv o	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	MuyBi en	MuyM al	NoRin de	Reprobo	SI	Primera
208	I C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Mal	Muy Mal	Mal	Regula r	Regul ar	NoRin de	Aprobo	SI	Primera

Francisco Rodríguez Morales | 138
Habilitación Profesional

209	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Reg ular	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
210	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	MuyB ien	Mal	NoAp lica	Reg ular	MuyM al	Regul ar	NoRin de	Aprobo	SI	Primera
211	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Regul ar	Bien	Mal	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
212	I E C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
213	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Bien	Mal	Muy Mal	Muy Mal	Regula r	Mal	NoRin de	Reprobo	SI	Primera
214	I E C I	Baj o	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Bien	Muy Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	NO	Primera
215	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
216	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
217	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	Buena	PrimerS em	MC	Muy Mal	Bien	Muy Mal	Reg ular	Mal	Mal	Regul ar	Aprobo	SI	Primera
218	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Regul ar	Muy Mal	Muy Mal	Mal	Bien	Mal	Muy Mal	Reprobo	SI	Primera
219	I E	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera

Francisco Rodríguez Morales | 139
Habilitación Profesional

	C																		
220	I	Regu	Regu	Bien	Munici	Norma	SinInfor	PrimerS	CV	Muy	Muy	Muy	Mal	MuyM	MuyM	NoRin	Reprobo	SI	Primera
221	E	Regu	Regu	Muy	Subven	Mucho	SinInfor	SinInfor	CV	Mal	Mal	NoAp	Mal	Bien	Mal	Mal	Reprobo	SI	Primera
222	E	Regu	Buen	Bien	Munici	Norma	SinInfor	SinInfor	CV	Muy	Muy	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	NO	Primera
223	I	Regu	Regu	Muy	Munici	Mucho	SinInfor	PrimerS	MC	Mal	Bien	NoAp	Regu	Regula	Regul	NoRin	Aprobo	SI	Primera
224	E	Regu	Regu	Muy	Munici	Mucho	SinInfor	PrimerS	MC	Muy	Muy	NoAp	Muy	MuyBi	MuyM	NoRin	Reprobo	SI	Primera
225	I	Regu	Regu	Bien	Subven	Norma	Regular	PrimerS	MC	Muy	NoRi	Muy	Muy	NoRin	NoCu	NoRin	Reprobo	NO	Primera
226	E	Regu	Regu	Regu	Particul	Norma	SinInfor	PrimerS	MC	MuyB	Regul	NoAp	Muy	MuyM	Regul	NoRin	Aprobo	SI	Primera
227	E	Regu	Regu	Muy	Munici	Mucho	SinInfor	SinInfor	CV	Muy	Mal	NoAp	Regu	MuyBi	Mal	Mal	Reprobo	SI	Primera
228	I	Regu	Regu	Bien	Munici	Mucho	Buena	PrimerS	MC	MuyB	Bien	Bien	Bien	NoRin	Regul	NoRin	Aprobo	SI	Primera
229	E	Regu	Regu	Muy	Munici	Norma	SinInfor	PrimerS	MC	MuyB	Muy	NoAp	Muy	Bien	Bien	NoRin	Aprobo	SI	Primera

Francisco Rodríguez Morales | 140
Habilitación Profesional

230	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Regul ar	Muy Mal	Muy Mal	Regul ar	Mal	Mal	Muy Mal	Reprobo	SI	Primera
231	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Mal	Muy Mal	Muy Mal	Bien	MuyM al	Mal	Muy Mal	Reprobo	SI	Primera
232	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	MuyB ien	Regul ar	Regul ar	NoRi nde	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
233	I C I	Baj o	Bajo	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
234	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	SI	Primera
235	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
236	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Mal	NoAp lica	Mal	MuyBi en	Mal	Muy Mal	Reprobo	SI	Primera
237	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	MuyBi en	MuyM al	Muy Mal	Reprobo	SI	Primera
238	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Regul ar	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
239	I E C I	Bue no	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Regul ar	Muy Mal	NoAp lica	Mal	MuyBi en	Mal	Muy Mal	Reprobo	SI	Primera
240	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	MuyB ien	Bien	NoAp lica	Muy Bien	Regula r	Bien	NoRin de	Aprobo	SI	Segunda

Francisco Rodríguez Morales | 141
Habilitación Profesional

241	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	MuyB ien	Bien	Mal	NoRi nde	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
242	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
243	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	NoRi nde	NoRi nde	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
244	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	Muy Mal	Muy Mal	Reg ular	NoRin de	MuyM al	NoRin de	Reprobo	SI	Primera
245	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Bien	Mal	NoAp lica	Mal	Regula r	Regul ar	NoRin de	Aprobo	SI	Primera
246	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Mucho	MuyBaj a	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	NoRi nde	Mal	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
247	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Regular	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	NoRin de	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
248	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	Mal	Muy Mal	Muy Mal	Regula r	MuyM al	NoRin de	Reprobo	SI	Primera
249	I E C I	Baj o	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	MuyBi en	MuyM al	Mal	Aprobo	SI	Primera
250	I E C I	Reg ular	Regul ar	Muy Bien	Particul arPag	Norma l	SinInfor macion	PrimerS em	MC	Bien	Mal	NoAp lica	Reg ular	Mal	Regul ar	NoRin de	Aprobo	SI	Primera
251	I	Reg	Regul	Bien	Subven	Norma	SinInfor	PrimerS	MC	Regul	Mal	NoAp	Muy	MuyM	Mal	Mal	Reprobo	SI	Primera

Francisco Rodríguez Morales | 142
Habilitación Profesional

	E C I	ular	ar		cionado	I	macion	em		ar		lica	Mal	al					
252	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	SinInfor macion	PrimerS em	MC	Mal	NoRi nde	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
253	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	SinInfor macion	SinInfor macion	CV	Mal	Mal	NoAp lica	Reg ular	NoRin de	Mal	Regul ar	Aprobo	SI	Primera
254	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
255	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	SinInfor macion	PrimerS em	MC	Regul ar	MuyB ien	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
256	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	SinInfor macion	PrimerS em	CV	Bien	Regul ar	NoAp lica	Bien	Regula r	Regul ar	NoRin de	Aprobo	SI	Primera
257	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	Buena	PrimerS em	MC	MuyB ien	Regul ar	Bien	Reg ular	Mal	Regul ar	NoRin de	Aprobo	SI	Segunda
258	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	MuyBu ena	PrimerS em	MC	Bien	Mal	Regul ar	Bien	Mal	Regul ar	NoRin de	Aprobo	SI	Primera
259	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	SinInfor macion	SinInfor macion	CV	Mal	Mal	NoAp lica	Bien	NoRin de	Mal	Bien	Aprobo	SI	Primera
260	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	Baja	PrimerS em	MC	NoRi nde	NoRi nde	NoAp lica	NoRi nde	NoRin de	SinNot a	NoRin de	Reprobo	NO	Primera
261	I C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	CV	MuyB ien	Mal	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
262	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	Buena	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Reg ular	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera

Francisco Rodríguez Morales | 143
Habilitación Profesional

	I																		
263	I E C I	Bajo	Regular	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Bien	Bien	NoAp lica	Reg ular	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
264	I E C I	Regu lar	Regu lar	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Regul ar	Regul ar	NoAp lica	Mal	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
265	I E C I	Regu lar	Regu lar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Regul ar	Muy Mal	NoAp lica	Muy Mal	Bien	Mal	NoRin de	Reprobo	SI	Primera
266	I E C I	Regu lar	Regu lar	Muy Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Reg ular	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
267	I E C I	Regu lar	Regu lar	Muy Bien	Particul arPag	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
268	I C I	Regu lar	Regu lar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Bien	NoRin de	MuyM al	Muy Mal	Reprobo	SI	Primera
269	I C I	Regu lar	Regu lar	Muy Bien	Munici pal	Excesiv o	Buena	PrimerS em	MC	Muy Mal	Muy Mal	Muy Mal	Muy Mal	MuyM al	MuyM al	Mal	Reprobo	SI	Primera
270	I C I	Regu lar	Regu lar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera
271	I E C I	Regu lar	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	MuyB ien	Bien	NoAp lica	Reg ular	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
272	I E C I	Regu lar	Regu lar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
273	I	Reg	Buen	Bien	Munici	Mucho	SinInfor	PrimerS	MC	Bien	Regul	NoAp	Muy	MuyBi	Bien	NoRin	Aprobo	SI	Primera

Francisco Rodríguez Morales | 144
Habilitación Profesional

	E C I	ular	o		pal		macion	em			ar	lica	Bien	en		de			
274	I C I	Bajo	Regular	Muy Bien	Municipal	Normal	SinInformacion	SinInformacion	CV	Muy Mal	Muy Mal	NoAplica	Bien	NoRinde	MuyMal	Muy Mal	Reprobo	SI	Primera
275	I E C I	Regular	Regular	Muy Bien	Municipal	Normal	Buena	PrimerSem	MC	Bien	Muy Mal	Muy Mal	Regular	Bien	MuyMal	NoRinde	Reprobo	SI	Primera
276	I E C I	Regular	Regular	Bien	Municipal	Mucho	Baja	PrimerSem	MC	Mal	Muy Mal	NoAplica	Muy Mal	MuyMal	MuyMal	NoRinde	Reprobo	SI	Primera
277	I C I	Regular	Regular	Muy Bien	Municipal	Normal	SinInformacion	SinInformacion	CV	Mal	Muy Mal	NoAplica	Bien	NoRinde	Mal	Muy Mal	Reprobo	SI	Primera
278	I C I	Regular	Regular	Bien	Subvencionado	Normal	SinInformacion	PrimerSem	CV	Muy Mal	Muy Mal	NoAplica	Regular	MuyMal	MuyMal	NoRinde	Reprobo	NO	Primera
279	I C I	Regular	Regular	Muy Bien	Subvencionado	Normal	SinInformacion	PrimerSem	CV	Bien	Muy Mal	Muy Mal	Bien	Regular	Mal	Muy Mal	Reprobo	SI	Primera
280	I E C I	Regular	Regular	Bien	Subvencionado	Mucho	SinInformacion	PrimerSem	MC	Bien	Mal	NoAplica	Bien	Mal	Regular	NoRinde	Aprobo	SI	Primera
281	I E C I	Regular	Bueno	Bien	Municipal	Normal	SinInformacion	SinInformacion	CV	Mal	Muy Mal	NoAplica	Muy Mal	MuyMal	MuyMal	NoRinde	Reprobo	NO	Primera
282	I E C I	Regular	Regular	Bien	Municipal	Normal	SinInformacion	PrimerSem	MC	Bien	Muy Mal	NoAplica	Muy Mal	MuyMal	MuyMal	Muy Mal	Reprobo	SI	Primera
283	I E C I	Bueno	Regular	Bien	Municipal	Mucho	SinInformacion	SinInformacion	CV	Bien	MuyBien	NoAplica	Bien	MuyBien	MuyBien	NoRinde	Aprobo	SI	Primera

Francisco Rodríguez Morales | 145
Habilitación Profesional

284	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Regul ar	Muy Mal	Muy Mal	Bien	MuyM al	MuyM al	Muy Mal	Reprobo	SI	Primera
285	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
286	I C I	Baj o	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Regul ar	Mal	Mal	NoRi nde	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Segunda
287	I E C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Regul ar	NoAp lica	Mal	Bien	Bien	NoRin de	Aprobo	SI	Primera
288	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
289	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Regul ar	NoAp lica	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
290	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Regul ar	NoAp lica	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
291	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Mal	NoAp lica	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
292	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Bien	Muy Mal	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
293	I E C I	Bue no	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Segunda
294	I C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma l	Regular	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Mal	NoRin de	NoCu mpleR equisi	NoRin de	Reprobo	NO	Primera

Francisco Rodríguez Morales | 146
Habilitación Profesional

																tos				
295	I E C I	Bue no	MuyB ueno	Muy Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Muy Mal	Mal	Mal	Regul ar	Reprobo	SI	Primera	
296	I E C I	Regu lar	Regul ar	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	MuyB ien	Regul ar	Bien	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera	
297	I C I	Regu lar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	MuyB ien	NoRi nde	NoAp lica	NoRi nde	MuyBi en	MuyBi en	NoRin de	Aprobo	NO	Primera	
298	I C I	Regu lar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Mal	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera	
299	I C I	Regu lar	Regul ar	Muy Bien	Munici pal	Excesiv o	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	Muy Mal	Mal	MuyBi en	Mal	Muy Mal	Reprobo	SI	Primera	
300	I C I	Regu lar	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Regu lar	Bien	MuyM al	NoRin de	Aprobo	SI	Primera	
301	I E C I	Regu lar	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Mal	Muy Mal	NoAp lica	Muy Mal	Regula r	MuyM al	NoRin de	Reprobo	SI	Primera	
302	I E C I	Regu lar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Regul ar	Muy Mal	NoAp lica	Muy Mal	Bien	Mal	Muy Mal	Reprobo	SI	Primera	
303	I C I	Regu lar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	Mal	NoAp lica	Regu lar	Bien	Regul ar	NoRin de	Aprobo	SI	Primera	
304	I E C I	Regu lar	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Regul ar	Mal	Muy Mal	Bien	Bien	Mal	NoRin de	Reprobo	SI	Primera	
305	I E C I	Regu lar	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera	

Francisco Rodríguez Morales | 147
Habilitación Profesional

	I																		
306	I E C I	Reg ular	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Bien	Muy Mal	NoAp lica	Muy Mal	Bien	Bien	NoRin de	Aprobo	SI	Primera
307	I E C I	Baj o	Regul ar	Muy Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	MuyB ien	Muy Mal	NoAp lica	Muy Mal	Bien	Mal	Muy Mal	Reprobo	SI	Primera
308	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Bien	NoAp lica	Reg ular	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
309	I C I	Bue no	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	MuyB ien	Muy Mal	NoAp lica	Bien	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
310	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Bien	NoRin de	Mal	Mal	Aprobo	SI	Primera
311	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Bien	Muy Mal	Muy Mal	Bien	Regula r	Mal	NoRin de	Reprobo	SI	Primera
312	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Muy Mal	Muy Mal	Muy Mal	Bien	MuyBi en	MuyM al	Regul ar	Reprobo	SI	Primera
313	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	MuyB ien	Mal	NoAp lica	Muy Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Segunda
314	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	MuyBu ena	PrimerS em	MC	Regul ar	Mal	Muy Mal	Reg ular	Regula r	Mal	NoRin de	Reprobo	SI	Primera
315	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
316	I	Reg	Buen	Bien	Subven	Norma	SinInfor	SinInfor	CV	Muy	Muy	NoAp	Reg	MuyM	MuyM	NoRin	Reprobo	SI	Primera

Francisco Rodríguez Morales | 148
Habilitación Profesional

	E C I	ular	o		cionado	I	macion	macion		Mal	Mal	lica	ular	al	al	de			
317	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	SinInfor macion	Segund oSem	CV	Muy Mal	Mal	NoAp lica	Muy Bien	Bien	Mal	Mal	Aprobo	SI	Segunda
318	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma I	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Bien	NoRin de	Mal	Muy Mal	Reprobo	SI	Primera
319	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	SinInfor macion	PrimerS em	CV	Mal	Muy Mal	Muy Mal	Reg ular	Bien	Mal	Muy Mal	Reprobo	SI	Primera
320	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	MuyBu ena	PrimerS em	MC	Regul ar	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
321	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
322	I C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	CV	Bien	Mal	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
323	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma I	SinInfor macion	Segund oSem	CV	Muy Mal	Bien	NoAp lica	Muy Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Segunda
324	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma I	MuyBu ena	PrimerS em	MC	Bien	Mal	Regul ar	Muy Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
325	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma I	SinInfor macion	SinInfor macion	CV	Mal	Mal	NoAp lica	Bien	Bien	Mal	Mal	Reprobo	SI	Primera
326	I E C	Bue no	Buen o	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	MuyB ien	Mal	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera

Francisco Rodríguez Morales | 149
Habilitación Profesional

	I																		
327	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Mal	Muy Mal	Mal	Muy Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
328	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Bien	NoRi nde	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	NO	Primera
329	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Mal	Regul ar	Mal	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
330	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Mal	Muy Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
331	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBaj a	PrimerS em	MC	Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
332	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
333	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	MuyB ien	Bien	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
334	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Regul ar	Mal	NoAp lica	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
335	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	MuyB ien	Bien	Muy Bien	Regula r	Bien	NoRin de	Aprobo	SI	Primera
336	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Bien	Regula r	Mal	MuyBi en	Reprobo	SI	Primera

Francisco Rodríguez Morales | 150
Habilitación Profesional

	C																		
337	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Bien	Muy Mal	NoAp lica	Muy Mal	Bien	Mal	NoRin de	Reprobo	SI	Primera
338	I C I	Reg ular	Buen o	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Muy Mal	MuyB ien	Mal	Muy Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
339	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Reg ular	Mal	Mal	Regul ar	Aprobo	SI	Primera
340	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Mal	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
341	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Muy Mal	Bien	Mal	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
342	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	MuyB ien	Regul ar	NoAp lica	Bien	MuyBi en	MuyBi en	NoRin de	Aprobo	SI	Primera
343	I E C I	Reg ular	Regul ar	Bien	Munici pal	Excesiv o	SinInfor macion	PrimerS em	MC	MuyB ien	Muy Mal	NoAp lica	Muy Mal	Regula r	Regul ar	NoRin de	Aprobo	SI	Primera
344	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	Buena	PrimerS em	MC	MuyB ien	Muy Mal	Mal	Reg ular	Bien	Mal	NoRin de	Reprobo	SI	Primera
345	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Reg ular	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
346	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Bien	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
347	I	Reg	Regul	Muy	Munici	Norma	SinInfor	SinInfor	CV	Bien	Muy	NoAp	Bien	NoRin	Regul	NoRin	Aprobo	SI	Primera

Francisco Rodríguez Morales | 151
Habilitación Profesional

	C	ular	ar	Bien	pal	I	macion	macion			Mal	lica		de	ar	de			
348	I	Bue	Regul	Muy	Munici		SinInfor	PrimerS	CV	Mal	Muy	Muy		MuyBi	Mal	NoRin	Reprobo	SI	Primera
349	E	Regul	Regul	Muy	Munici	Norma	SinInfor	PrimerS	MC	Bien	Bien	NoAp	Mal	Bien	Bien	NoRin	Aprobo	SI	Primera
350	E	Regul	Regul	Bien	Munici	Norma	SinInfor	PrimerS	MC	Mal	Muy	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	SI	Primera
351	I	Regul	Regul	Bien	Subven	Norma	SinInfor	PrimerS	CV	MuyB	Mal	NoAp	Bien	MuyBi	Bien	NoRin	Aprobo	SI	Primera
352	E	Bue	Buen	Bien	Munici	Norma	SinInfor	SinInfor	CV	Muy	Muy	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	NO	Primera
353	E	Regul	Buen	Muy	Subven	Norma	SinInfor	Segund	CV	Regul	MuyB	NoAp	Muy	Bien	Bien	NoRin	Aprobo	SI	Segunda
354	I	Regul	Regul	Bien	Subven	Norma	SinInfor	PrimerS	CV	Mal	Muy	Muy	Bien	MuyM	MuyM	NoRin	Reprobo	SI	Primera
355	E	Regul	Regul	Muy	Munici	Norma	SinInfor	SinInfor	CV	Bien	Mal	NoAp	Bien	Bien	Regul	NoRin	Aprobo	SI	Primera
356	E	Regul	Buen	Bien	Munici	Norma	SinInfor	SinInfor	CV	Regul	Muy	NoAp	Bien	Bien	Mal	Muy	Reprobo	SI	Primera
357	I	Bue	Regul	Muy	Munici	Norma	Buena	PrimerS	MC	Muy	NoRi	NoAp	Mal	NoRin	MuyM	NoRin	Reprobo	NO	Primera
358	I	Reg	Regul	Bien	Munici	Mucho	Regular	PrimerS	MC	Bien	MuyB	Bien	Bien	Bien	Bien	NoRin	Aprobo	SI	Segunda

Francisco Rodríguez Morales | 152
Habilitación Profesional

	C	ular	ar		pal			em			ien				de				
359	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Mal	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
360	I E C I	Bue no	Buen o	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Bien	Mal	NoAp lica	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Segunda
361	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	Bien	Muy Mal	Muy Mal	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
362	I E C I	Baj o	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Mal	NoAp lica	Reg ular	NoRin de	MuyM al	NoRin de	Reprobo	SI	Primera
363	I E C I	Bue no	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Mal	Mal	MuyM al	Regul ar	Reprobo	SI	Primera
364	I E C I	Bue no	Buen o	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Bien	Muy Mal	NoAp lica	Muy Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Segunda
365	I E C I	Reg ular	Regul ar	Bien	Particul arPag	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	Bien	MuyB ien	Muy Bien	Regula r	MuyBi en	NoRin de	Aprobo	SI	Primera
366	I E C I	Reg ular	Bajo	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	Regul ar	Muy Mal	Muy Mal	Muy Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera
367	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
368	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	NO	Primera

Francisco Rodríguez Morales | 153
Habilitación Profesional

	I																		
369	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Regul ar	Regul ar	NoAp lica	Bien	Mal	Regul ar	NoRin de	Aprobo	SI	Primera
370	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	Justifica do	PrimerS em	MC	Muy Mal	Mal	Muy Mal	Muy Mal	Bien	MuyM al	Mal	Reprobo	SI	Segunda
371	I C I	Bue no	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Mal	NoAp lica	Bien	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
372	I E C I	Reg ular	Bajo	Muy Bien	Munici pal	Mucho	Buena	PrimerS em	MC	Regul ar	Muy Mal	NoAp lica	Muy Mal	Regula r	MuyM al	NoRin de	Reprobo	NO	Primera
373	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
374	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	CV	NoRi nde	NoRi nde	NoAp lica	Muy Bien	NoRin de	SinNot a	NoRin de	Reprobo	NO	Primera
375	I E C I	Reg ular	Regul ar	Bien	Munici pal	Excesiv o	SinInfor macion	PrimerS em	MC	NoRi nde	NoRi nde	NoAp lica	NoRi nde	NoRin de	SinNot a	NoRin de	Reprobo	NO	Primera
376	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Regul ar	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
377	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Bien	Mal	NoAp lica	Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
378	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Reg ular	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
379	I E I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Mal	NoAp lica	Muy Bien	Bien	Mal	Mal	Aprobo	SI	Segunda

Francisco Rodríguez Morales | 154
Habilitación Profesional

	C																		
380	I E C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
381	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Regul ar	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
382	I E C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
383	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Bien	Bien	Mal	Muy Mal	Reprobo	SI	Primera
384	I C I	Bue no	Buen o	Muy Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Bien	Bien	NoAp lica	Bien	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
385	I C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Bien	NoAp lica	Reg ular	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
386	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Regul ar	NoAp lica	Bien	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
387	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
388	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Excesiv o	SinInfor macion	Segund oSem	CV	Regul ar	MuyB ien	NoAp lica	Muy Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Segunda
389	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
390	I E C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	Mal	Muy Mal	NoAp lica	Muy Bien	MuyBi en	Mal	Bien	Aprobo	SI	Segunda

Francisco Rodríguez Morales | 155
Habilitación Profesional

	I																		
391	IEC	Bueno	Bueno	Bien	Municipal	Normal	SinInformacion	SegundoSem	CV	Mal	Mal	NoAplica	MuyBien	MuyBien	Regular	NoRinde	Aprobo	SI	Segunda
392	IC	Regular	Regular	MuyBien	Municipal	Normal	SinInformacion	SinInformacion	CV	Bien	MuyBien	NoAplica	MuyMal	NoRinde	Bien	NoRinde	Aprobo	SI	Primera
393	IEC	Regular	Regular	MuyBien	Subvencionado	Mucho	Buena	PrimerSem	MC	Bien	Regular	Mal	Bien	Bien	Regular	NoRinde	Aprobo	SI	Primera
394	IC	Regular	Regular	Bien	Subvencionado	Normal	SinInformacion	SegundoSem	CV	MuyBien	MuyBien	MuyBien	NoRinde	MuyBien	MuyBien	NoRinde	Aprobo	SI	Primera
395	IEC	Regular	Regular	Bien	Municipal	Mucho	SinInformacion	PrimerSem	CV	Bien	Mal	Regular	Mal	Mal	Bien	NoRinde	Aprobo	SI	Primera
396	IEC	Regular	Regular	Bien	Subvencionado	Normal	Buena	PrimerSem	MC	MuyMal	MuyMal	MuyMal	MuyMal	MuyMal	MuyMal	NoRinde	Reprobo	SI	Primera
397	IEC	Regular	Regular	MuyBien	Subvencionado	Normal	SinInformacion	SinInformacion	CV	MuyMal	MuyMal	NoAplica	MuyMal	Bien	MuyMal	NoRinde	Reprobo	SI	Primera
398	IC	Regular	Regular	Bien	Subvencionado	Normal	SinInformacion	PrimerSem	CV	Bien	MuyMal	NoAplica	Bien	MuyBien	Regular	NoRinde	Aprobo	SI	Primera
399	IEC	Regular	Regular	Bien	Municipal	Normal	SinInformacion	SegundoSem	CV	Mal	Mal	NoAplica	Bien	Bien	Mal	NoRinde	Reprobo	SI	Segunda
400	IC	Regular	Regular	MuyBien	Subvencionado	Normal	Buena	PrimerSem	MC	MuyMal	NoRinde	MuyMal	Mal	Bien	MuyMal	NoRinde	Reprobo	SI	Primera
401	IE	Regular	Regular	MuyBien	Subvencionado	Mucho	SinInformacion	SinInformacion	CV	MuyMal	MuyMal	NoAplica	MuyMal	MuyMal	MuyMal	NoRinde	Reprobo	NO	Primera

Francisco Rodríguez Morales | 156
Habilitación Profesional

	C																		
402	I E C I	Reg ular	Buen o	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Muy Bien	Bien	MuyM al	Muy Mal	Reprobo	SI	Segunda
403	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Reg ular	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
404	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Reg ular	NoRin de	MuyM al	NoRin de	Reprobo	SI	Primera
405	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Mal	Muy Mal	NoAp lica	Reg ular	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
406	I E C I	Reg ular	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Reg ular	Mal	Mal	Mal	Reprobo	SI	Primera
407	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Mal	Muy Mal	Muy Mal	Muy Mal	MuyM al	MuyM al	Muy Mal	Reprobo	SI	Primera
408	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Bien	MuyBi en	Mal	Regul ar	Aprobo	SI	Primera
409	I E C I	Reg ular	Regul ar	Bien	Munici pal	Excesiv o	MuyBaj a	PrimerS em	MC	NoRi nde	NoRi nde	NoAp lica	NoRi nde	NoRin de	SinNot a	NoRin de	Reprobo	NO	Primera
410	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Regul ar	NoAp lica	Reg ular	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
411	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	Regular	PrimerS em	MC	Muy Mal	Muy Mal	Mal	Bien	Bien	NoCu mpleR equisi tos	Muy Mal	Reprobo	SI	Segunda
412	I C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	MuyBu ena	PrimerS em	MC	Muy Mal	Bien	Mal	Muy Bien	Regula r	Regul ar	NoRin de	Aprobo	SI	Primera

Francisco Rodríguez Morales | 157
Habilitación Profesional

	I																		
413	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	Regul ar	Regul ar	Muy Mal	Muy Bien	Bien	Regul ar	MuyBi en	Aprobo	SI	Primera
414	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	Mal	NoAp lica	Reg ular	MuyBi en	Mal	Muy Mal	Reprobo	SI	Primera
415	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
416	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Bien	NoAp lica	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Segunda
417	I E C I	Reg ular	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Segunda
418	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Mal	Mal	NoAp lica	Reg ular	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
419	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	MuyB ien	Mal	NoAp lica	Bien	Regula r	Bien	NoRin de	Aprobo	NO	Primera
420	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	MuyB ien	Regul ar	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
421	I E C I	Reg ular	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Bien	Regul ar	NoAp lica	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
422	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Muy Mal	Muy Mal	Muy Mal	Muy Bien	Bien	Mal	Muy Mal	Reprobo	SI	Primera
423	I	Reg	Regul	Bien	Munici	Norma	SinInfor	PrimerS	CV	MuyB	Mal	NoAp	Bien	MuyBi	Bien	NoRin	Aprobo	SI	Primera

Francisco Rodríguez Morales | 158
Habilitación Profesional

	C	ular	ar		pal	I	macion	em		ien		lica		en		de			
424	I	Reg	Regul	Reg	Munici	Norma	SinInfor	PrimerS	CV	Muy	Muy	NoAp	Reg	MuyBi	MuyBi	NoRin	Aprobo	SI	Primera
425	E	Reg	Regul	Bien	Munici	Norma	Justifica	PrimerS	MC	Muy	Muy	Muy	Mal	Bien	MuyM	NoRin	Reprobo	SI	Segunda
426	I	Reg	Regul	Bien	Particul	Norma	SinInfor	SinInfor	CV	Muy	Mal	NoAp	Bien	NoRin	Mal	Regul	Aprobo	SI	Primera
427	I	Reg	Regul	Bien	Subven	Excesiv	Buena	SinInfor	MC	Muy	Muy	NoAp	Muy	Bien	MuyM	NoRin	Reprobo	SI	Segunda
428	I	Reg	Regul	Bien	Munici	Norma	SinInfor	PrimerS	CV	NoRi	NoRi	NoAp	Muy	Bien	SinNot	NoRin	Reprobo	NO	Primera
429	E	Reg	Regul	Bien	Munici	Mucho	SinInfor	SinInfor	CV	Bien	Mal	NoAp	Reg	Bien	Regul	NoRin	Aprobo	SI	Primera
430	I	Reg	Buen	Bien	Subven	Norma	SinInfor	SinInfor	CV	Mal	Muy	NoAp	Mal	Bien	MuyM	Muy	Reprobo	SI	Primera
431	E	Reg	Regul	Muy	Munici	Norma	Buena	PrimerS	MC	Regul	Bien	Muy	Muy	MuyM	Mal	Bien	Aprobo	SI	Segunda
432	I	Reg	Regul	Bien	Munici	Norma	SinInfor	Segund	CV	Bien	Bien	MuyB	NoRi	MuyBi	MuyBi	NoRin	Aprobo	SI	Primera
433	I	Reg	Regul	Bien	Subven	Norma	MuyBu	PrimerS	MC	Mal	MuyB	Mal	Muy	MuyBi	Bien	NoRin	Aprobo	SI	Primera
434	E	Bue	Buen	Muy	Particul	Excesiv	SinInfor	SinInfor	CV	Muy	Muy	NoAp	Muy	MuyM	MuyM	NoRin	Reprobo	NO	Primera

Francisco Rodríguez Morales | 159
Habilitación Profesional

	I																		
435	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
436	I E C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Bien	NoAp lica	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
437	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	Baja	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Reg ular	MuyM al	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
438	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Bien	NoRin de	Mal	Muy Mal	Aprobo	SI	Primera
439	I E C I	Bue no	Buen o	Muy Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyBi en	MuyM al	NoRin de	Reprobo	NO	Segunda
440	I E C I	Bue no	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Bien	Mal	NoAp lica	Muy Mal	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
441	I E C I	Reg ular	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Muy Bien	Bien	MuyM al	NoRin de	Reprobo	SI	Segunda
442	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Mal	NoAp lica	Reg ular	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
443	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
444	I C I	Bue no	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	Muy Mal	Mal	Muy Mal	Bien	Bien	Mal	Muy Mal	Reprobo	SI	Primera
445	I C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	Regular	PrimerS em	MC	Muy Mal	Regul ar	Mal	Mal	NoRin de	NoCu mpleR	NoRin de	Reprobo	NO	Primera

Francisco Rodríguez Morales | 160
Habilitación Profesional

	I														equisitos				
446	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Regul ar	Mal	NoAp lica	Regul ar	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
447	I C I	Baj o	Bajo	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	Muy Mal	NoRi nde	Muy Mal	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	NO	Primera
448	I C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	Regul ar	Bien	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
449	I E C I	Regul ar	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Segunda
450	I C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Regul ar	Muy Mal	NoAp lica	Bien	MuyBi en	Mal	Regul ar	Aprobo	SI	Primera
451	I E C I	Regul ar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Bien	Regul ar	NoAp lica	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Segunda
452	I C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Bien	NoRin de	Mal	NoRin de	Reprobo	SI	Primera
453	I C I	Regul ar	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
454	I C I	Regul ar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	MC	MuyB ien	Bien	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
455	I C I	Regul ar	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	MuyB ien	Mal	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
456	I E C I	Regul ar	Buen o	Muy Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Regul ar	NoAp lica	Muy Bien	MuyBi en	Mal	Regul ar	Aprobo	SI	Segunda
457	I	Reg	Regul	Bien	Subven	Mucho	SinInfor	PrimerS	CV	MuyB	Muy	NoAp	Bien	MuyBi	Bien	NoRin	Aprobo	SI	Primera

Francisco Rodríguez Morales | 161
Habilitación Profesional

	C	ular	ar		cionado		macion	em		ien	Mal	lica		en		de			
458	I E C I	Baj o	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	Muy Mal	Muy Mal	MuyM al	MuyM al	Muy Mal	Reprobo	SI	Primera
459	I E C I	Regul ar	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	SinInfor macion	CV	Regul ar	Muy Mal	NoAp lica	Mal	Bien	Mal	Muy Mal	Reprobo	SI	Primera
460	I E C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Mal	Mal	Muy Mal	Bien	Bien	Mal	NoRin de	Reprobo	SI	Primera
461	I C I	Regul ar	Regul ar	Muy Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Bien	Bien	Bien	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
462	I C I	Regul ar	Bajo	Muy Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Bien	Bien	Bien	NoRi nde	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
463	I E C I	Regul ar	Buen o	Muy Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Bien	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
464	I E C I	Regul ar	Buen o	Bien	Particul arPag	Mucho	SinInfor macion	Segund oSem	CV	Bien	Bien	NoAp lica	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Segunda
465	I C I	Regul ar	Buen o	Bien	Subven cionado	Mucho	MuyBu ena	PrimerS em	MC	Mal	MuyB ien	Muy Mal	Muy Bien	Mal	Regul ar	NoRin de	Aprobo	SI	Primera
466	I E C I	Bue no	Buen o	Bien	Munici pal	Excesiv o	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
467	I E C I	Regul ar	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Muy Mal	Mal	MuyM al	NoRin de	Reprobo	SI	Primera

Francisco Rodríguez Morales | 162
Habilitación Profesional

468	I C I	Reg ular	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	MC	MuyB ien	Bien	NoAp lica	Bien	MuyBi en	MuyBi en	NoRin de	Aprobo	SI	Primera
469	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Bien	NoRin de	MuyM al	Muy Mal	Reprobo	SI	Primera
470	I C I	Bue no	Regul ar	Muy Bien	Munici pal	Excesiv o	SinInfor macion	SinInfor macion	CV	Regul ar	Bien	NoAp lica	Bien	NoRin de	Bien	NoRin de	Aprobo	SI	Primera
471	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	MuyBu ena	PrimerS em	MC	MuyB ien	MuyB ien	Mal	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
472	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Primera
473	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	Baja	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	NoRin de	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
474	I E C I	Reg ular	Regul ar	Bien	Munici pal	Mucho	SinInfor macion	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	NoRi nde	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
475	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
476	I E C I	Reg ular	Buen o	Muy Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Muy Mal	NoAp lica	Muy Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
477	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	Baja	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Regul ar	NoRin de	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
478	I E C I	Bue no	Buen o	Bien	Subven cionado	Mucho	SinInfor macion	Segund oSem	CV	MuyB ien	Muy Mal	NoAp lica	Muy Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Segunda

Francisco Rodríguez Morales | 163
Habilitación Profesional

479	I C I	Reg ular	Regul ar	Bien	Subven cionado	Excesiv o	SinInfor macion	PrimerS em	CV	Regul ar	Muy Mal	Muy Mal	Regul ar	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
480	I C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Bien	NoAp lica	Muy Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
481	I C I	Regul ar	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	MuyB ien	NoAp lica	Muy Bien	MuyBi en	MuyBi en	NoRin de	Aprobo	SI	Primera
482	I C I	Regul ar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Regul ar	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
483	I C I	Regul ar	Buen o	Muy Bien	Subven cionado	Mucho	MuyBaj a	PrimerS em	MC	NoRi nde	NoRi nde	NoAp lica	NoRi nde	NoRin de	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
484	I E C I	Regul ar	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Mal	NoAp lica	Muy Mal	MuyBi en	Mal	Regul ar	Aprobo	SI	Primera
485	I C I	Regul ar	Buen o	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Regul ar	Regul ar	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
486	I C I	Bue no	Buen o	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	MuyB ien	MuyB ien	Mal	Muy Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
487	I C I	Regul ar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	Bien	NoAp lica	Regul ar	Bien	Bien	NoRin de	Aprobo	SI	Primera
488	I C I	Regul ar	Regul ar	Bien	Particul arPag	Norma l	SinInfor macion	PrimerS em	CV	Mal	Muy Mal	NoAp lica	Mal	Bien	MuyM al	NoRin de	Reprobo	SI	Primera
489	I E C I	Regul ar	Regul ar	Muy Bien	Munici pal	Norma l	Buena	PrimerS em	MC	Muy Mal	Muy Mal	NoAp lica	Mal	NoRin de	MuyM al	NoRin de	Reprobo	NO	Primera
490	I C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Bien	MuyM al	Mal	MuyBi en	Reprobo	SI	Segunda

Francisco Rodríguez Morales | 164
Habilitación Profesional

491	I E C I	Reg ular	Buen o	Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Mal	Regul ar	NoAp lica	Muy Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Segunda
492	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	MuyB ien	Mal	NoAp lica	Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
493	I C I	Reg ular	Regul ar	Reg ular	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
494	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	MuyB ien	Regul ar	NoAp lica	Bien	Bien	Bien	NoRin de	Aprobo	SI	Primera
495	I E C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Muy Mal	MuyM al	MuyM al	NoRin de	Reprobo	SI	Primera
496	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Reg ular	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
497	I C I	Reg ular	Regul ar	Bien	Munici pal	Norma l	SinInfor macion	SinInfor macion	CV	Mal	Bien	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
498	I C I	Reg ular	Regul ar	Muy Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyBi en	MuyM al	Muy Mal	Reprobo	SI	Primera
499	I C I	Baj o	Bajo	Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyBi en	MuyBi en	NoRin de	Aprobo	SI	Primera
500	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	PrimerS em	CV	Bien	Bien	NoAp lica	Muy Bien	MuyBi en	Bien	NoRin de	Aprobo	SI	Primera
501	I C I	Reg ular	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
502	I C I	Reg ular	Regul ar	Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Muy Mal	Muy Mal	NoAp lica	Bien	NoRin de	MuyM al	Muy Mal	Reprobo	SI	Primera
503	I	Reg	Regul	Reg	Munici	Mucho	SinInfor	PrimerS	MC	Muy	Muy	NoAp	Bien	Bien	MuyM	NoRin	Reprobo	SI	Primera

Francisco Rodríguez Morales | 165
Habilitación Profesional

	E C I	ular	ar	ular	pal		macion	em		Mal	Mal	lica			al	de			
504	I E C I	Bue no	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	Segund oSem	CV	Muy Mal	Bien	NoAp lica	Muy Bien	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Segunda
505	I E C I	Regul ar	Buen o	Muy Bien	Subven cionado	Norma l	SinInfor macion	SinInfor macion	CV	Bien	Muy Mal	NoAp lica	Bien	Bien	Regul ar	NoRin de	Aprobo	SI	Primera
506	I C I	Regul ar	Regul ar	Muy Bien	Munici pal	Norma l	SinInfor macion	PrimerS em	CV	Bien	Muy Mal	NoAp lica	Mal	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
507	I E C I	Regul ar	Buen o	Bien	Munici pal	Norma l	SinInfor macion	Segund oSem	CV	Muy Mal	Muy Mal	NoAp lica	Mal	MuyM al	MuyM al	NoRin de	Reprobo	NO	Segunda
508	I C I	Regul ar	Regul ar	Bien	Munici pal	Excesiv o	SinInfor macion	SinInfor macion	CV	Mal	Regul ar	NoAp lica	Bien	NoRin de	Regul ar	NoRin de	Aprobo	SI	Primera
509	I E C I	Regul ar	Regul ar	Bien	Munici pal	Mucho	Regular	PrimerS em	MC	Muy Mal	NoRi nde	NoAp lica	Muy Mal	Mal	NoCu mpleR equisi tos	NoRin de	Reprobo	NO	Primera
510	I C I	Regul ar	Regul ar	Bien	Subven cionado	Mucho	SinInfor macion	PrimerS em	CV	Regul ar	Mal	NoAp lica	Regul ar	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera
511	I E C I	Regul ar	Regul ar	Bien	Subven cionado	Norma l	Buena	PrimerS em	MC	Muy Mal	Muy Mal	Bien	Mal	MuyBi en	Regul ar	NoRin de	Aprobo	SI	Primera