



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA

FACULTAD DE INGENIERÍA

**EVALUACIÓN ESTRUCTURAL DE PAVIMENTOS FLEXIBLES
CON MÉTODOS DE INTELIGENCIA ARTIFICIAL Y
AUSCULTACIÓN NO DESTRUCTIVA**

TESIS

Para optar por el grado de

DOCTORA EN INGENIERÍA

INGENIERÍA CIVIL - GEOTECNIA

PRESENTADA POR

GLORIA INÉS BELTRÁN CALVO

TUTOR

DR. MIGUEL PEDRO ROMO ORGANISTA



México, D.F., 2012

JURADO ASIGNADO

| | |
|---------------|----------------------------------|
| Presidente | Dr. OVANDO SHELLEY EFRAÍN |
| Secretario | Dr. RIVERA CONSTANTINO RIGOBERTO |
| Vocal | Dr. ROMO ORGANISTA MIGUEL PEDRO |
| 1er. Suplente | Dr. MENDOZA LÓPEZ MANUEL JESÚS |
| 2do. Suplente | Dr. OROZCO SANTOYO RAÚL VICENTE |

Lugar de realización de la tesis:
Instituto de Ingeniería, Universidad Nacional Autónoma de México

TUTOR DE TESIS
Dr. Miguel Pedro Romo Organista

Firma

Dedicatoria

*A Juan Carlos
por estar siempre ahí
regalándome su amor incondicional*

*A Daniela y Juan Esteban
por llenar mi existencia
de besitos de mariposa*

*A Natis
por volver a florecer
en la primavera de su vida*

AGRACEDIMIENTOS

Al Dr. Miguel Pedro Romo Organista por su paciencia, acompañamiento y generosidad al compartir su experiencia y sabiduría, haciendo más grato el camino de la investigación.

A los miembros del Jurado asignado, quienes enriquecieron continuamente mi formación y aportaron valiosos comentarios y consejos para mejorar este documento.

Al Instituto de Ingeniería, a la Facultad de Ingeniería y a la UNAM, por brindarme el apoyo y la oportunidad de pertenecer a esta gran familia de seres y conocimientos.

Al Dr. Ángel Kuri y al Dr. Ángel López, profesores del programa de posgrado en Ciencias e Ingeniería de la Computación de la UNAM, por sus enseñanzas sobre aspectos fundamentales de redes neuronales artificiales y lógica difusa.

A la Universidad Nacional de Colombia por hacer posible mi estancia en México.

Al Centro Latinoamericano de Física – CLAF y al Instituto de Ciencia y Tecnología del Distrito Federal - ICyTDF, por el apoyo otorgado en el marco del programa de intercambio, formación y capacitación de recursos humanos latinoamericanos.

A mis apreciados amigos en México, quienes procuraron hacerme sentir como en casa.

A toda mi familia, por acompañarme y alentarme en la distancia.

ÍNDICE

| | | |
|----------|---|-----------|
| 1 | INTRODUCCIÓN | 1 |
| 1.1 | PLANTEAMIENTO DE LA INVESTIGACIÓN | 2 |
| 1.2 | ANTECEDENTES | 5 |
| 2 | GENERALIDADES | 11 |
| 2.1 | SISTEMAS DE ADMINISTRACIÓN DE PAVIMENTOS - SAPS | 11 |
| 2.2 | PANORAMA GENERAL DE LA RED DE CARRETERAS EN MÉXICO | 12 |
| 2.3 | PAVIMENTOS FLEXIBLES EN SERVICIO | 14 |
| 2.4 | TÉCNICAS DE AUSCULTACIÓN | 16 |
| 3 | COMPONENTES DE LA EVALUACIÓN ESTRUCTURAL | 21 |
| 3.1 | ESPEORES Y MATERIALES DE LAS CAPAS | 21 |
| 3.2 | EVALUACIÓN DEL COMPORTAMIENTO MECÁNICO DEL PAVIMENTO | 22 |
| 3.2.1 | Esfuerzos y deformaciones en los pavimentos | 22 |
| 3.2.2 | Resistencia y rigidez de las capas | 24 |
| 3.2.3 | Estimación de módulos de capa a partir de pruebas de deflexión | 27 |
| 3.2.4 | Indicadores estructurales derivados de pruebas de deflexión | 33 |
| 3.3 | EVALUACIÓN DEL DETERIORO ESTRUCTURAL | 38 |
| 3.4 | DEFINICIÓN DE SECTORES HOMOGÉNEOS DE COMPORTAMIENTO | 42 |
| 3.5 | MODELOS DE DETERIORO | 44 |
| 4 | HERRAMIENTAS DE LA INTELIGENCIA ARTIFICIAL | 49 |
| 4.1 | REDES NEURONALES ARTIFICIALES - RNAs | 49 |
| 4.1.1 | Estructura de las RNAs | 51 |
| 4.1.2 | Diseño de un modelo neuronal | 52 |
| 4.1.3 | Modelación de un problema | 56 |
| 4.1.4 | Evaluación del desempeño de la modelación neuronal | 58 |
| 4.2 | LÓGICA DIFUSA - LD | 59 |
| 4.2.1 | Conjuntos difusos | 59 |
| 4.2.2 | Reglas de inferencia difusa y operaciones entre conjuntos | 61 |
| 4.2.3 | Sistemas de inferencia difusa - SIDs | 65 |
| 4.2.4 | Agrupamiento difuso | 69 |
| 4.3 | SISTEMAS BASADOS EN RNAs Y LD | 69 |
| 5 | PLANTEAMIENTO METODOLÓGICO Y CASO APLICADO | 73 |
| 5.1 | CONFORMACIÓN DE LAS BASES DE DATOS | 75 |
| 5.2 | ANÁLISIS PRELIMINARES | 76 |
| 5.3 | IDENTIFICACIÓN DE PARÁMETROS MECÁNICOS MEDIANTE RNAs | 85 |
| 5.3.1 | Diseño del modelo neuronal para estimar módulos de capa | 86 |
| 5.3.2 | Evaluación del ajuste de cuencas de deflexión | 88 |
| 5.3.3 | Capacidad de generalización de la RNAóp | 92 |
| 5.3.4 | Influencia de la Relación de Poisson | 92 |
| 5.3.5 | Análisis de resultados de la modelación con RNAs | 95 |
| 5.4 | EVALUACIÓN ESTRUCTURAL DEL PAVIMENTO USANDO HERRAMIENTAS DE LA LD | 98 |
| 5.4.1 | Diseño de los Sistemas de Inferencia Difusa - SIDs | 98 |
| 5.4.2 | Evaluación de los SIDs diseñados – Análisis de resultados | 103 |
| 5.4.3 | Identificación de sectores homogéneos | 106 |

| | | |
|----------|---|------------|
| 5.5 | DEFINICIÓN DE SOLUCIONES | 108 |
| 5.5.1 | Intervenciones Potenciales | 108 |
| 5.5.2 | Sistema de inferencia para las soluciones - SID _{Soluciones} | 109 |
| 5.5.3 | Evolución del deterioro y vida remanente | 115 |
| 5.6 | SÍNTESIS DE LOS MODELOS CON RNAs Y SIDS PROPUESTOS | 122 |
| 6 | CONCLUSIONES | 125 |
| 7 | RECOMENDACIONES | 131 |
| | REFERENCIAS BIBLIOGRÁFICAS | 135 |
| | ANEXO A: ASPECTOS HISTÓRICOS SOBRE INTELIGENCIA ARTIFICIAL | 145 |
| | ANEXO B: RESULTADOS DE LOS SIDS PARA EL CORREDOR VIAL | 153 |
| | ANEXO C: ALGORITMOS DESARROLLADOS - SISTEMAS DE INFERENCIA DIFUSOS | 163 |

LISTADO DE FIGURAS

| | | |
|-------------|--|----|
| Figura 2.1 | Fases de la gestión con enfoque a nivel de proyecto – AASHTO (1993) | 12 |
| Figura 3.1 | Respuesta del pavimento ante carga – variables críticas | 23 |
| Figura 3.2 | Relación de Poisson | 25 |
| Figura 3.3 | Módulo resiliente a partir de prueba cíclica de carga | 26 |
| Figura 3.4 | Pulso de fuerza transmitido en pruebas de deflexión | 27 |
| Figura 3.5 | Prueba de deflexión por impacto y cuenca de deflexión. | 28 |
| Figura 3.6 | Solución tradicional al problema del cálculo inverso | 30 |
| Figura 3.7 | Área aproximada de la cuenca de deflexión | 34 |
| Figura 3.8 | Resistencia de pavimentos según $D_{m\acute{a}x}$ y AN0.9 | 35 |
| Figura 3.9 | Determinación del índice estructural | 36 |
| Figura 3.10 | Zonas de curvatura en cuencas de deflexión | 37 |
| Figura 3.11 | Deformaciones permanentes o roderas | 39 |
| Figura 3.12 | Algunos tipos de deterioro estructural | 39 |
| Figura 3.13 | Conceptos que definen las diferencias acumuladas de áreas | 43 |
| Figura 3.14 | Definición de sectores en función de Z_c | 44 |
| Figura 4.1 | Esquema funcional de una neurona artificial | 50 |
| Figura 4.2 | Configuración básica de un modelo de red neuronal | 51 |
| Figura 4.3 | Funciones de activación comúnmente usadas | 55 |
| Figura 4.4 | Posibles tendencias de la función de error | 56 |
| Figura 4.5 | Representación clásica y difusa de una variable. | 60 |
| Figura 4.6 | Interpretación de las funciones de pertenencia - condición por grietas | 61 |
| Figura 4.7 | Operador O - unión de conjuntos | 62 |
| Figura 4.8 | Representación difusa de la variable condición por baches | 63 |
| Figura 4.9 | Operador Y - intersección entre conjuntos | 63 |
| Figura 4.10 | Variable consecuente difusa: condición de un pavimento | 64 |
| Figura 4.11 | Regla difusa con implicación Y | 64 |
| Figura 4.12 | Estructura general del SID propuesto por Mandami | 66 |
| Figura 4.13 | Mecanismo de inferencia y defusificación en el SID de Mandami. | 67 |
| Figura 4.14 | Estructura general del SID TSK | 67 |
| Figura 5.1 | Proceso metodológico desarrollado | 74 |

| | | |
|-------------|--|-----|
| Figura 5.2 | Ubicación del tramo vial seleccionado y sección típica | 75 |
| Figura 5.3 | Características medidas en el corredor analizado | 77 |
| Figura 5.4 | Indicadores estructurales deducidos de las cuencas de deflexión | 79 |
| Figura 5.5 | Clasificación de la capacidad de soporte en función de AN y D _{máx} | 80 |
| Figura 5.6 | Relación entre los índices I _e y D _{máx} | 81 |
| Figura 5.7 | Relación entre índices de forma de las cuencas y D _{máx} | 82 |
| Figura 5.8 | Respuestas de deflexión diferentes con indicadores similares | 83 |
| Figura 5.9 | Indicadores de rigidez y forma de la cuenca | 84 |
| Figura 5.10 | Sectores por diferencias acumuladas de I _e y D _{máx} | 85 |
| Figura 5.11 | Configuración del modelo neuronal propuesto | 87 |
| Figura 5.12 | Proceso de cálculo de módulos mediante RNA | 88 |
| Figura 5.13 | Proceso de evaluación del ajuste de deflexiones | 89 |
| Figura 5.14 | Deflexiones medidas y calculadas – carril derecho | 91 |
| Figura 5.15 | Tendencia del error durante el entrenamiento y prueba | 91 |
| Figura 5.16 | Verificación del ajuste de deflexiones - carril izquierdo | 93 |
| Figura 5.17 | Módulos de capa estimados para el carril izquierdo | 94 |
| Figura 5.18 | Sistema de inferencia para evaluar la rigidez | 100 |
| Figura 5.19 | Sistema de inferencia difuso para evaluar el deterioro | 102 |
| Figura 5.20 | Caracterización estructural del corredor | 106 |
| Figura 5.21 | Sistema de inferencia difuso para la evaluación integral | 110 |
| Figura 5.22 | Calificaciones e intervenciones en el ejemplo de 3 km | 113 |
| Figura 5.23 | Calificación estructural integral del corredor | 113 |
| Figura 5.24 | Intervenciones propuestas por sector | 114 |
| Figura 5.25 | Tendencias en la evolución del agrietamiento | 116 |
| Figura 5.26 | Tendencias en la evolución de la profundidad de roderas | 117 |
| Figura 5.27 | Progresión de la profundidad de roderas | 118 |
| Figura 5.28 | Programación de intervenciones en tramos con roderas y grietas | 120 |
| Figura 5.29 | Estructura final de las modelaciones desarrolladas con RNAs y SIDs | 123 |

LISTADO DE TABLAS

| | | |
|------------|---|----|
| Tabla 2.1 | Longitud de Carreteras Nacionales en México (km)- Año2010 | 12 |
| Tabla 2.2 | Evaluación de la condición global de pavimentos flexibles | 16 |
| Tabla 3.1 | Valores típicos de parámetros mecánicos del pavimento | 27 |
| Tabla 3.2 | Condición en función de $D_{m\acute{a}x}$ y el TPD (<i>Barrantes et al, 2008</i>) | 33 |
| Tabla 3.3 | Condición según el área de la cuenca de deflexión (<i>Orozco 2005</i>) | 34 |
| Tabla 3.4 | Características de resistencia en función del área normalizada y $D_{m\acute{a}x}$ | 35 |
| Tabla 3.5 | Condición del pavimento según el Índice estructural (<i>Orozco, 2005</i>) | 36 |
| Tabla 3.6 | Factores de forma de las cuencas de deflexión y otros indicadores | 38 |
| Tabla 3.7 | Indicadores estructurales e intervalos de variación | 38 |
| Tabla 3.8 | Valores sugeridos para juzgar la condición por deterioro | 40 |
| Tabla 3.9 | Soluciones recomendadas por agencias internacionales según deterioro | 40 |
| Tabla 3.10 | Índice de Condición del Pavimento – PCI | 41 |
| Tabla 3.11 | Índice de degradación superficial – Is | 41 |
| Tabla 3.12 | Criterios locales para evaluar la condición por deterioro | 42 |
| Tabla 3.13 | Valores de carga para cada grupo de ejes. | 47 |
| Tabla 3.14 | ESALF por tipo de vehículo | 48 |
| Tabla 3.15 | Coefficientes del modelo de deformación estructural | 48 |
| Tabla 4.1 | Algoritmos de aprendizaje y arquitecturas usuales en RNAs | 53 |
| Tabla 4.2 | Características de algunos algoritmos de aprendizaje | 54 |
| Tabla 4.3 | Calidad del ajuste entre valores medidos y estimados | 58 |
| Tabla 4.4 | Comparación entre sistemas basados en RNAs y sistemas difusos | 70 |
| Tabla 5.1 | Bases de datos global y específicas | 76 |
| Tabla 5.2 | Espesores de capas del pavimento (m) | 78 |
| Tabla 5.3 | Distribución de datos que indican deficiencias estructurales (%) | 78 |
| Tabla 5.4 | Caracterización del pavimento según forma de la cuenca | 84 |
| Tabla 5.5 | Opciones consideradas en el análisis de sensibilidad | 87 |
| Tabla 5.6 | Resumen de resultados del ajuste de deflexiones – carril derecho | 90 |
| Tabla 5.7 | Módulos estimados y esperados – carril derecho | 91 |
| Tabla 5.8 | Relaciones de Poisson estimadas con RNAs | 93 |
| Tabla 5.9 | Análisis de sensibilidad de variables | 97 |

| | | |
|------------|---|-----|
| Tabla 5.10 | Consideraciones para el sistema de reglas de inferencia - rigidez | 101 |
| Tabla 5.11 | Consideraciones para el sistema de reglas de inferencia por deterioro | 103 |
| Tabla 5.12 | Condición por rigidez del pavimento a partir del SID-Rigidez | 104 |
| Tabla 5.13 | Deterioro del pavimento a partir del SID-Deterioro | 105 |
| Tabla 5.14 | Clasificación de la condición de rigidez y deterioro por sector (%) | 107 |
| Tabla 5.15 | Principales Actividades de mantenimiento según SCT | 108 |
| Tabla 5.16 | Listado de posibles intervenciones | 109 |
| Tabla 5.17 | Escala de calificación y acciones globales | 109 |
| Tabla 5.18 | Matriz de decisión para el sistema de reglas - SIDSoluciones | 111 |
| Tabla 5.19 | Condición estructural integral y soluciones – SIDSolución | 112 |
| Tabla 5.20 | Progresión del agrietamiento | 116 |
| Tabla 5.21 | Vida remanente según la progresión de profundidad de rodera | 117 |
| Tabla 5.22 | Resultados consolidados de la evaluación estructural | 121 |

RESUMEN

La investigación doctoral, se enmarca dentro de los sistemas de administración de pavimentos flexibles para corredores viales. En este trabajo se propone un Sistema no convencional, para realizar tareas asociadas con la evaluación estructural de pavimentos y la toma de decisiones de conservación, con el fin de garantizar condiciones de operación satisfactorias durante el servicio.

En el planteamiento del sistema, convergen algunas herramientas de la inteligencia artificial, tales como las redes neuronales artificiales y la lógica difusa, junto con las técnicas tradicionales de análisis, el conocimiento y la experiencia de especialistas y conceptos mecánico-empíricos de ingeniería de pavimentos. Los últimos quedaron involucrados en la modelación del deterioro y la estimación de la vida remanente del pavimento, mientras que las prácticas convencionales se aplicaron para caracterizaciones preliminares y para identificar las variables más influyentes en los problemas abordados.

Las redes neuronales se plantean para estimar, mediante cálculo inverso, los módulos y las relaciones de Poisson de las capas que conforman un pavimento, a partir de pruebas no destructivas de deflexión. Este enfoque permitió modelar adecuadamente la respuesta del pavimento y resolver el problema de identificación de parámetros, considerando su carácter no lineal, multivariado y complejo. En el diseño del modelo neuronal, se realizó una intensa labor para lograr la red óptima, en términos de precisión y tiempo de cómputo; igualmente, se estudió la influencia de las relaciones de Poisson en la estimación de módulos de capa. Estos dos aspectos han sido abordados débilmente en investigaciones previas.

Mediante la aplicación de las técnicas de lógica difusa, se diseñaron tres sistemas para inferir la condición de rigidez, de deterioro y las recomendaciones de conservación, expresados en términos lingüísticos para facilitar su interpretación y comprensión. Los sistemas integran las variables de carácter subjetivo y cualitativo, utilizadas comúnmente para describir los niveles de severidad del deterioro.

Para el desarrollo de los modelos, se utilizaron datos de auscultación no destructiva registrados en sistemas de pavimento de tres y cuatro capas, incluyendo estructuras tradicionales y estructuras invertidas. Gracias al uso de bases de datos reales, las simulaciones lograron reproducir adecuadamente el fenómeno físico representativo del pavimento, superando las limitaciones de trabajos previos desarrollados con datos sintéticos y estructuras hipotéticas.

Comparando los comportamientos observados y los estimados, se encontró que el sistema propuesto permite representar de manera bastante aproximada las características reales del pavimento; por ello, resulta razonable concluir que puede utilizarse con confianza para la evaluación estructural de pavimentos flexibles, con muy bajo costo computacional.

ABSTRACT

This work is focused on management systems for existing flexible pavements at project level. A non-conventional modelling System is proposed to identify the structural adequacy and potential maintenance solutions for pavements to provide proper operating condition.

The System is based on traditional analyses, expert knowledge, mechanical-empirical concepts of pavement engineering and soft computing techniques such as Artificial Neural Networks and Fuzzy Logic. Traditional analyses were applied for preliminary characterization and to identify the most significant variables for simulations. Mechanical-empirical concepts were considered for deterioration modelling and remaining life estimation.

Neural networks are proposed for estimating elastic moduli of constituent layers of pavement from non-destructive deflection testing, through back-calculation method. This approach allows modelling the pavement response, dealing with a complex, non-linear and multivariate parameter identification problem. A hard work to design the optimum ANN is done; also, the influence of Poisson's ratio on layer moduli estimation is studied here. These two issues have been poorly addressed in previous investigations.

On the other hand, three Fuzzy Inference Systems are developed to address the stiffness - deterioration characterization and conservation decisions, expressed linguistically to facilitate the interpretation and understanding of the final results. Fuzzy logic tools are applied to represent linguistic variables of subjective and qualitative nature, commonly used to describe the severity levels of deterioration; thus they can be involved directly into structural characterization of pavements. Expert knowledge is taken into account in the definition of such fuzzy representations.

The modelling system was developed from a database gathered from field tests performed on three and four layer pavement systems, that included traditional layer structuring and pavements having a subbase stiffer than their granular base. By using real databases, the physical phenomenon of pavement can be properly represented, overcoming the constraints of previous works based on synthetic and hypothetical data.

By comparing predicted and observed behaviours, it was found that pavement features are well mapped by the proposed modelling; it was shown the ability of the system to reproduce very closely, the physical phenomenon representative of actual pavement's behavior. Hence, based on the high quality of results obtained, it seems reasonable to conclude that the proposed model can be used confidently for structural evaluation of flexible pavements. Furthermore, it is possible to perform analyses under particular considerations with low computational cost.

1 INTRODUCCIÓN

Con el continuo desarrollo y consolidación de la red de carreteras en el país, ha sido necesario promover la aplicación de sistemas que permitan administrar y gestionar la infraestructura como un bien público y social. Estos sistemas constituyen instrumentos de apoyo y optimización de toma de decisiones para garantizar la conservación de la infraestructura de carreteras, proporcionando condiciones satisfactorias de estabilidad, funcionalidad y seguridad al transporte terrestre, con una transferencia razonable de costos a los usuarios.

La evaluación de los pavimentos en servicio constituye el principal insumo de cualquier sistema con el que se pretenda administrar la infraestructura vial, pues permite determinar la condición de las carreteras en determinados periodos, bajo las condiciones reales de operación; en función de ello, se puede establecer la vida remanente de la infraestructura, las alternativas de rehabilitación, costos, prioridades e incluso el impacto y beneficio obtenido con su aplicación.

La intuición humana ha servido como base para la toma de decisiones, pero hoy en día se hace necesario acudir a técnicas y herramientas que puedan ayudar al proceso, dada la rapidez que se requiere en las decisiones, el costo de los errores que se puedan cometer, la gran cantidad de factores a tener en cuenta (análisis multi-criterio) y la diversidad de alternativas de solución que existen. De ahí, el reto constante de la ingeniería de vías terrestres por mejorar los procesos a través de metodologías cada vez más eficientes y confiables.

Es precisamente en esa dirección en la cual se conduce esta investigación doctoral, planteando un sistema que combina los recursos intelectuales de los expertos, las capacidades de las herramientas de cómputo y la información técnica disponible, para identificar problemas y tomar decisiones oportunas de conservación de pavimentos con buenos niveles de confianza.

A continuación presenta el planteamiento de la investigación, incluyendo los problemas abordados, los objetivos, los alcances, las aportaciones y los antecedentes considerados como relevantes.

1.1 Planteamiento de la investigación

El tema de investigación se enmarca dentro de los **sistemas de administración a nivel de proyecto** para **pavimentos flexibles** en servicio. Se da énfasis al manejo, procesamiento y análisis de información técnica que conduzca a establecer las posibles intervenciones para mantener condiciones adecuadas de servicio, otorgando la debida relevancia que tiene la evaluación de la **condición estructural** de un pavimento en la toma de decisiones sobre la conservación.

Se entiende que cualquier acción que se proponga para mejorar la capacidad estructural, mejora simultáneamente otras características de serviciabilidad. Con ello, no se pretende desconocer la importancia que tienen los demás componentes en la evaluación global, sino más bien acotar los alcances de la investigación en función de la información disponible, hacia problemas muy específicos que aún constituyen “baches” por superar.

A continuación se presentan algunas de las dificultades, deficiencias o limitaciones que aún persisten para evaluar o caracterizar estructuralmente los pavimentos.

Problemas abordados

Manejo de variables cualitativas. En el inventario de deterioro realizado durante la etapa de inspección visual en campo, se registran variables de carácter subjetivo que otorgan descripciones lingüísticas y dan una valoración cualitativa al pavimento; aunque estas variables constituyen una parte valiosa de la evaluación y su registro puede ser dispendioso, terminan considerándose como un indicador periférico en los análisis, o en el mejor de los casos se les asocia un valor constante según criterio del analista para poder involucrarlo de algún modo.

Modelación del comportamiento e identificación de parámetros. Una de las principales dificultades a afrontar en la simulación del sistema estructural de pavimento, es la representación de la resistencia y la rigidez. Aunque se ha llegado a planteamientos teóricos o teórico-experimentales, para estimar parámetros de comportamiento mecánico, tales como los módulos de capa, los niveles de confiabilidad son inciertos dada la cantidad de simplificaciones que se realizan; adicionalmente, puede desecharse información importante por restricciones en algunos modelos disponibles, en cuanto a capacidad de procesamiento o altos costos computacionales.

Los resultados obtenidos bajo estas condiciones, terminan siendo ampliamente aceptados en virtud de la misma complejidad del problema, aunque muchas veces no reflejan la verdadera naturaleza del mismo: dinámico, no lineal, heterogéneo.

En algunos trabajos previos se han aplicado aproximaciones con RNAs para estimar módulos de capas, pero la mayoría de los casos reportados se basan en modelos desarrollados a partir de datos sintéticos de auscultación, estructuras hipotéticas de pavimento o ambos. En estas simulaciones, la capacidad de predicción ha estado limitada por la calidad de las bases de datos

empleadas; es decir, no se pueden extrapolar los estimativos más allá de los valores usados para el desarrollo de tales modelos.

Análisis de información. Para la evaluación de corredores viales, regularmente se definen sectores homogéneos que quedan caracterizados por propiedades promedio, las cuales se extrapolan a todos los puntos de cada sector; en función de la condición media se definen las intervenciones. Esta práctica se realiza para simplificar los análisis, pues aunque las evaluaciones punto a punto proporcionan un panorama bastante detallado de un corredor, consumen gran cantidad de tiempo.

Interpretación de resultados. La mayoría de las herramientas utilizadas para la evaluación y toma de decisiones, requieren cierta habilidad de interpretación de los resultados, por parte del analista, para que puedan ser comprendidos y aplicados finalmente por las entidades encargadas de la conservación y mantenimiento de vialidades.

Formulación de acciones de mantenimiento. En esta etapa, el criterio de expertos juega un papel fundamental; desafortunadamente, el conocimiento, buen juicio y experiencia acumulada por muchos años de los especialistas, difícilmente quedan automatizados para que puedan utilizarse en la toma de decisiones para casos posteriores. De otro lado, es usual que la toma de decisiones se base en unos cuantos parámetros de control asumidos por las entidades encargadas de la conservación; generalmente solo se consideran acciones donde existe deterioro y rara vez se integran criterios asociados con la rigidez.

Objetivos

Para enfrentar las situaciones descritas, en esta investigación se abordan metodologías basadas en experiencias multidisciplinarias exitosas desarrolladas en el campo de la Inteligencia Artificial, considerando distintas facetas del problema para lograr simulaciones “buenas y razonables” con bajo costo computacional.

El objetivo general que persigue la investigación, es estructurar un sistema de modelación no convencional, basado en Redes Neuronales Artificiales - RNAs y Lógica Difusa - LD, para identificar parámetros de comportamiento de pavimentos, establecer la condición de rigidez y deterioro e identificar posibles intervenciones en sectores con problemas.

Dentro de los objetivos específicos, se pretende:

- i) Identificar las variables que más influyen en los problemas abordados, mediante análisis paramétricos.
- ii) Identificar parámetros de rigidez de las capas constitutivas de pavimentos (módulos de capa y relaciones de Poisson), a partir de pruebas no destructivas de deflexión por impacto, usando RNAs. Se optó por esta técnica, gracias al potencial que ofrece para identificar relaciones no lineales en problemas multivariados complejos.

- iii) Establecer la condición de rigidez y deterioro, junto con las posibles soluciones en sectores con problemas, utilizando Sistemas de Inferencia Difusos – SIDs. Se espera a) Integrar las variables lingüísticas cualitativas y el conocimiento de expertos, directamente en los análisis y en la toma de decisiones; b) realizar análisis punto a punto de manera rápida, para contar con un panorama integral del comportamiento en el que se apoye la definición de sectores homogéneos y tramos críticos; c) orientar las recomendaciones de conservación con base en análisis multivariados, expresando los resultados en términos lingüísticos para facilitar su interpretación y comprensión.

Para desarrollar el sistema, se utilizan datos de auscultación no destructiva medida sobre un caso de estudio seleccionado, procurando modelaciones apegadas al fenómeno físico representativo del comportamiento. Las bases de datos empleadas, contiene información sobre estructuras de pavimentos de tres y cuatro capas, incluyendo sistemas tradicionales donde la rigidez de las capas decrece con la profundidad y estructuras con sección invertida.

Alcances

En la investigación se da prioridad al *diseño* de los modelos neuronales y los sistemas de inferencia, realizando los *análisis de sensibilidad* necesarios para garantizar eficiencia y buenos niveles de precisión de las simulaciones. De igual forma, se da especial importancia a los procesos de *validación* que permitan probar que los modelos diseñados reflejan de manera confiable las respuestas, el comportamiento y desempeño real de los pavimentos.

Considerando que las modelaciones planteadas se desarrollan a partir de auscultaciones realizadas en una época específica durante el servicio de una vía, no se involucra el efecto de variaciones de tipo ambiental que sin duda afectan el comportamiento de los pavimentos. En este aspecto, vale la pena aclarar que la única manera de estudiar el impacto real de variables como la temperatura y humedad, por ejemplo, es mediante tramos de prueba bajo condiciones controladas.

Aportaciones

La investigación constituye el primer trabajo estructurado en nuestro medio, en el cual se desarrolla un Sistema de modelación no convencional basado en RNAs y LD, para desarrollar diversas tareas asociadas con la evaluación de pavimentos: procesar información, identificar parámetros, modelar comportamientos, inferir la condición y acciones de conservación.

El Sistema aporta simplicidad, precisión (apego a la realidad) y rapidez; así mismo, constituye una posibilidad para superar algunas deficiencias de los métodos de evaluación tradicionales, pues permite:

- ✓ Considerar relaciones no lineales entre múltiples variables.
- ✓ Involucrar variables cualitativas y el conocimiento de expertos en los análisis.

- ✓ Tomar decisiones globales (por sector) y a nivel detallado (punto a punto).
- ✓ Expresar los resultados en términos lingüísticos.
- ✓ Formaliza la integración de criterios subjetivos de experiencias nacionales e internacionales para la evaluación y formulación de soluciones.
- ✓ Garantizar que las predicciones se encuentren dentro de órdenes de magnitud posibles en la práctica. Se avanza así, hacia la superación de las restricciones encontradas en modelos desarrollados con datos sintéticos y estructuras de pavimento hipotéticas.

Específicamente para determinar módulos de capa en pavimentos a partir de pruebas no destructivas de deflexión, se desarrolla un nuevo procedimiento para aumentar la capacidad de predicción de las RNAs, incluyendo estructuras de pavimento donde la rigidez no necesariamente decrece con la profundidad.

En ese mismo aspecto, se aportan elementos importantes para el diseño de una RNA “óptima”, pues son escasos los trabajos previos donde se aborda en detalle este proceso.

En este trabajo también se contribuye con una evaluación sobre la incidencia de la Relación de Poisson en la estimación de módulos de capa, situación que ha sido débilmente abordada en estudios previos.

Finalmente, se identifican algunas oportunidades adicionales en las cuales resulta útil la aplicación de herramientas de la inteligencia artificial, para desarrollar tareas asociadas con la evaluación de pavimentos flexibles en servicio y para orientar las decisiones en sistemas de administración.

1.2 Antecedentes

En la Coordinación de Geotecnia del Instituto de Ingeniería de la UNAM, se han desarrollado varias investigaciones en las cuales se han aplicado técnicas basadas en inteligencia artificial para la modelación de diversos problemas geotécnicos (Rangel (2002); García *et al.* (2002); Correa (2005); García y Romo (2005); Rojas (2005); Romo y García (2006); Echeverry (2006); García, (2004 y 2009), entre otros). Como resultado, se han desarrollado sistemas neuronales, sistemas híbridos neuro-difusos y neuro-genéticos, donde se combina la habilidad de *aprendizaje* de las redes neuronales, la capacidad de *interpretación del conocimiento* a través de la lógica difusa y la *adaptación* de los algoritmos genéticos.

Entre los problemas abordados se encuentran el diseño del soporte y procedimiento constructivo de túneles en macizos rocosos; la determinación de propiedades dinámicas en presas y en las arcillas de la ciudad de México para predecir respuestas ante eventos sísmicos; la predicción de desplazamientos laterales inducidos por fenómenos de licuación; la estimación de la velocidad de ondas de corte a partir de la resistencia a la penetración estándar; la evaluación del comportamiento de arenas y la atenuación espectral sísmica, entre otros.

Este trabajo constituye un aporte más a los esfuerzos que se están realizando para implementar el cómputo aproximado en la búsqueda de soluciones a problemas geotécnicos.

En particular, la ingeniería de carreteras y de pavimentos ha mostrado un interés especial en la aplicación de la inteligencia artificial para resolver problemas específicos asociados con sistemas de administración y gestión vial; ya se cuenta con experiencias exitosas en el ámbito internacional que demuestran el amplio potencial para poder considerarlas como herramientas de análisis complementarios no convencionales.

En los últimos 15 años, varias agencias han fomentado el uso de herramientas de inteligencia artificial para la solución de problemas específicos de carreteras. El TRB-Transportation Research Board, por ejemplo, creó el Comité AFS50 (1), denominado “Aplicación de herramientas computacionales no convencionales incluyendo redes neuronales”, con el ánimo de proporcionar a los profesionales una mejor comprensión y a la vez fomentar la aplicación de las RNA y otras herramientas, para la modelación y análisis del componente geotécnico en los sistemas de transporte y en su desempeño.

En la Universidad de Texas - El Paso, se han desarrollado diversos estudios para el Departamento de Transportes de Texas – TxDOT y para la Administración Federal de Carreteras –FHWA. Por ejemplo, Ferregut *et al* (1999) y Abdallah *et al* (2000) desarrollaron modelos con RNAs para estimar el espesor de la subrasante, las deformaciones críticas y los módulos de carpeta asfáltica, calculados sintéticamente mediante un modelo lineal elástico a partir de datos de deflexiones y espesores de capas; los resultados se utilizaron para estimar la vida remanente en pavimentos, bajo criterios de varias agencias. Los investigadores usaron una red independiente para predecir cada parámetro, con el ánimo de manejar redes muy simples, cuya configuración no dependiera de más de uno de esos parámetros.

Más tarde, Williams *et al* (2004) consideraron la Lógica Difusa como alternativa para combinar valores de módulos de capa, estimados mediante diferentes métodos a partir de datos de auscultación no destructiva (deflexión, propagación de ondas y georadar); esto con el fin de lograr un valor ponderado, en una técnica denominada de fusión de datos, utilizada cuando se cuenta con datos provenientes de diferentes fuentes para un mismo parámetro; en comparación con otros métodos, la técnica de LD ofreció los resultados más razonables.

En los anteriores estudios se utilizaron bases de datos sintéticas para el desarrollo de los modelos; Abdallah *et al* (2005a) revisaron la factibilidad y aplicación de las técnicas de integración de información y aplicaron los modelos para casos de estudio con datos medidos en campo (2005b).

En la Universidad de Illinois, Pekcan *et al* (2008), desarrollaron para el Departamento de Transporte de Illinois - IDOT's, dos programas de cómputo: i) SOFTSYS - Soft Computing Based Pavement and Geomaterial System Analyzer, para estimar el espesor de la capa asfáltica en estructuras de pavimentos “full-depth”; ii) ANN-Pro, para estimar propiedades mecánicas del

pavimento y eventualmente evaluar estrategias de rehabilitación. Los resultados obtenidos mediante cómputo aproximado, se acoplaron con Elemento Finito, para incorporar las respuestas críticas del pavimento dentro del método de análisis y diseño mecanicista del IDOT.

Adicional a estos esfuerzos, se han documentado varios estudios muy puntuales donde se utilizan técnicas de la Inteligencia Artificial – IA para resolver problemas de infraestructura vial, con resultados bastante promisorios para su uso a mayor escala. A continuación se mencionan aquellos de mayor interés para los alcances de esta investigación.

En particular para la gestión de pavimentos en servicio, Schwartz (1996) abordó el tema de las RNAs para predecir la condición de proyectos de infraestructura. Sundin & Braban-Ledoux en Suecia (2001), revisaron cerca de 40 artículos publicados entre los años 1987 y 1999; en ellos se plantean herramientas de apoyo basadas en sistemas expertos, RNA, LD, algoritmos genéticos y sistemas híbridos en tareas específicas de la administración de carreteras para: lograr más eficiencia global en los sistemas, realizar diagnósticos y modelación de deterioro en fases de análisis; identificar necesidades de rehabilitación y seleccionar acciones de mantenimiento en la fase de diseño; priorizar intervenciones en la fase de decisiones; captar el conocimiento y experiencia de los especialistas.

Desafortunadamente, la mayoría de los estudios consultados desarrollaron metodologías a partir de bases de datos sintéticas y aunque los autores reconocen el potencial que tiene la Inteligencia Artificial, como comentario final citan que *“El verdadero reto está en desarrollar aplicaciones que, en comparación con los modelos tradicionales, representen de mejor manera el desempeño de los pavimentos con base en datos reales medidos en campo”*.

Yella *et al* (2006) resumieron los principales hallazgos encontrados en un gran número de estudios, donde se utilizan herramientas de la inteligencia artificial para la interpretación automática de datos de auscultación no destructiva en una amplia variedad de problemas de inspección de infraestructura ferroviaria. Los autores encontraron ventajas significativas en el uso de estas técnicas para procesar grandes cantidades de información y para automatizar el conocimiento de expertos, con bajos costos computacionales y buenos niveles de precisión.

Sandra *et al* (2007) en India, presentaron una aproximación multi-criterio difusa para establecer órdenes de prioridad de rehabilitación en sectores carreteros, en función del Índice de Prioridad-IP, definido mediante la combinación de cinco indicadores de condición funcional y estructural. En ese estudio, se consideró la influencia que tiene la severidad de cada indicador por separado en la condición del pavimento.

En esa misma dirección, Ming *et al* (2009) en China, propusieron un sistema con RNAs para clasificar la condición de un pavimento en cinco categorías variando entre excelente a baja, integrando cinco indicadores.

En cuanto a la aplicación de herramientas de la IA para resolver el problema específico de identificación de parámetros, Goktepe *et al* (2005) mencionan once estudios efectuados entre los años 1993 y 2003, donde se usaron RNA y LD para estimar propiedades mecánicas de pavimentos a partir de datos de auscultación no destructiva.

Los primeros resultados de modelaciones con RNAs, se reportaron en los años 1990s (Meier y Rix (1994, 1995), Tutumluer y Meier (1996), Lee *et al* (1998)). Posteriormente, se efectuaron diversos trabajos en los cuales se utilizaron bases de datos sintéticas y/o estructuras hipotéticas de pavimentos para desarrollar las siguientes tareas:

- Modelar espesores de capas (Saltan *et al* 2002)
- Reducir tiempos de cómputo (Rakesh *et al* 2006)
- Estimar cuencas sintéticas de deflexión a partir de cargas hipotéticas aplicadas (Saltan *et al*, 2006)
- Crear nuevas cuencas de deflexión cuando los datos para construir una RNA confiable son escasos (Saltan y Terzi 2007)
- Evaluar el efecto de la configuración de las RNA en el desempeño de la modelación (Goktepe *et al* 2006; Sharma y Das 2008)

Dentro de los intentos por analizar datos reales medidos en campo mediante RNAs, se han realizado estudios para tareas muy específicas: Kim, *et al* (2000) utilizaron datos de impulsos de carga y emisión de ondas superficiales sobre el pavimento, para estimar módulos de capa; sin embargo, los resultados estuvieron limitados por la magnitud de las cargas usadas para la generación de ondas. Por su parte, Ceylan *et al* (2005) evaluaron sistemas de pavimento tipo *full-depth*, Saltan y Sezgin (2006) analizaron capas de subbase mientras Gopalakrishnan y Thompson (2004) y Gopalakrishnan y Ceylan (2008) evaluaron estructuras de pavimento en aeropuertos. En todos los casos, las RNAs brindaron aproximaciones confiables, con buenos niveles de precisión, eficientes y muy realistas.

Los trabajos más recientes se han enfocado hacia lograr modelaciones más eficientes y precisas usando algoritmos de optimización y modelos híbridos neuro-difusos o de RNA con elemento finito-EF. Por ejemplo, Saltan y Sezgin (2006) desarrollaron un modelo híbrido donde usaron RNA para encontrar parámetros de capas de subbase y EF para simular el comportamiento de los materiales y la carga vehicular.

Loizos *et al* (2007), utilizaron RNAs optimizadas con algoritmos genéticos para estimar módulos de capas granulares no ligadas en pavimentos. Gopalakrishnan y Khaitan (2010) también usaron un modelo de EF bidimensional para modelar el comportamiento de las capas granulares y para generar bases de datos sintéticas para el entrenamiento y prueba de un sistema híbrido neuro difuso, capaz de estimar módulos de capa asfáltica y de subrasante. Aunque se consideró promisorio el uso del modelo híbrido, en algún caso de estudio se hallaron niveles de error inaceptables atribuidos principalmente a la escasez de datos e iteraciones empleados para el

entrenamiento y al grado de incertidumbre en algunos datos de entrada. Otras investigaciones efectuadas con modelos híbridos neuro-genéticos son: Reddy *et al* (2004) y Rakesh *et al* (2006).

Entre las críticas más frecuentes asociadas con la aplicación de las RNAs como método de análisis, se ha mencionado que éstas no se apoyan en un análisis mecánico ni en un modelo de respuesta del problema, por lo cual se recomienda su aplicación de manera cuidadosa.

En contraste, Loizos *et al.* (2007) y Ceylan *et al.* (2009) señalan que las RNAs son especialmente útiles para modelar relaciones altamente no lineales entre datos y problemas complejos donde no se conoce *a priori* las leyes mecánicas a las cuales el problema obedece; es decir, para problemas donde los resultados son más importantes que las reglas que los explican. Por ello, resultan útiles cuando no existe una solución tradicional que pueda describir con precisión los parámetros que afectan los módulos de las capas del pavimento, ni el mecanismo real del comportamiento no-lineal y multi-variado que lo caracteriza. Por otra parte, no ha sido necesario asumir hipótesis simplificadoras para lograr modelaciones sencillas, lo que facilita su aplicación en la práctica.

Algunos estudios previos señalan que los estimativos con las RNAs, en especial cuando se trabaja con bases de datos sintéticas, no se pueden extrapolar más allá de los valores usados para el entrenamiento; es decir que la capacidad de predicción de las RNA se ve restringida por el rango, tamaño y distribución de los valores seleccionados para conformar las bases de datos. Cabe mencionar que esta no es una limitación exclusiva de las RNAs, puesto que cualquier método de análisis es sensible a las características de las base de datos utilizadas.

Por otro lado, se ha reportado que en el proceso iterativo propio de las RNAs para minimizar la función de error, puede darse una convergencia hacia un mínimo local sin poder garantizar que la solución hallada sea la mejor. Esta dificultad puede salvarse mediante la prueba y validación de los modelos neuronales con datos adicionales, para asegurar la convergencia global.

En cuanto a la eficiencia de las RNAs, hay quienes han logrado experiencias exitosas de análisis en tiempo real, y quienes encuentran que las modelaciones toman largos tiempos de entrenamiento, más aún cuando se acoplan con algoritmos genéticos (Goel y Das, 2007). Esto obviamente depende de la complejidad del problema y puede solucionarse mediante el uso apropiado de los algoritmos de optimización.

Goel y Das (2007), también mencionan como desventaja, el hecho de que las RNAs requieren re-entrenamiento cada vez que los parámetros de entrada cambian. En este aspecto, debe tenerse en mente que una de las bases de las RNAs, es precisamente la “plasticidad”, entendida como la capacidad de aprender siempre; así, la nueva información o parámetros pueden asimilarse en un proceso de aprendizaje a largo plazo, mejorando cada vez más la capacidad de predicción de la RNA.

Bajo este panorama, se considera que la inteligencia artificial puede jugar un rol importante tanto en el procesamiento eficiente de información, como en la modelación apropiada de sistemas estructurales de pavimento; la conveniencia o no de la aplicación de estas herramientas y el éxito que se obtenga, depende obviamente del tipo y conocimiento del problema que se quiere analizar.

Organización del Documento

El cuerpo del documento se encuentra dividido en dos partes esenciales. La primera está constituida por los capítulos 2 a 4, en los cuales se presentan aspectos teóricos que aportan una contextualización detallada de la temática analizada y de los recursos metodológicos empleados. En el capítulo 2, se incluyen conceptos generales sobre sistemas de administración y evaluación de pavimentos y su aplicación en el medio mexicano; en el capítulo 3 se describen los fundamentos sobre evaluación estructural de pavimentos en servicio y en el capítulo 4 las herramientas de la inteligencia artificial empleadas en la investigación.

La segunda parte del documento, constituye el aporte del trabajo investigativo realizado y está conformado por los capítulos 5 a 7. En el capítulo 5 se expone el modelo conceptual propuesto para la evaluación estructural y toma de decisiones; adicionalmente, se describe su aplicación en un caso de estudio, con la respectiva discusión de resultados, análisis y validación. En el capítulo 6 se incluyen las principales conclusiones derivadas de la investigación y en el capítulo 7 algunas recomendaciones prácticas.

2 GENERALIDADES

2.1 Sistemas de Administración de pavimentos - SAPs

El enfoque de los sistemas de administración o de gestión de carreteras, se basa en un conocimiento amplio sobre el estado de las vías y la definición clara de necesidades, para destinar presupuesto y ejecutar acciones de mantenimiento y conservación.

Los sistemas más modernos centralizan e integran los insumos necesarios en bases de datos con información completa sobre registros históricos de auscultación, intervenciones, tránsito, costos, entre otros. El manejo de estos sistemas en medios computacionales, permite la actualización periódica, el seguimiento histórico – evolutivo del desempeño, la verificación y validación de las hipótesis asumidas, la toma de decisiones y la retroalimentación para ajustar los pronósticos con base en las tendencias reales observadas, mejorando así la confiabilidad de la gestión. En general, se identifican tres posibles niveles o enfoques para los SAPs:

- i. *A nivel de estrategias* para redes a cargo de una organización o agencia, donde requiere información de carácter general para definir modelos óptimos en cuanto a prioridades e inversiones; su aplicación se da más que todo a nivel preventivo.
- ii. *A nivel de programas* de inversión para uno o más años, en el cual se seleccionan los proyectos por escalas de prioridad, en función de la relación Beneficio – Costo (B/C).
- iii. *A nivel de proyecto* para uno o pocos corredores específicos como alternativas de inversión. Se requiere información técnica y administrativa detallada de los corredores para plantear acciones tendientes a la rehabilitación.

Para el *enfoque a nivel de proyecto*, resultan aplicables las tres fases de desarrollo ilustradas en la Figura 2.1, sugeridas por la American Association of State Highway and Transportation Officials –AASHTO (1993). Los alcances de este trabajo de investigación se enmarcan dentro de la mayoría de las actividades que se desarrollan en las Fase I y II del proceso de gestión mencionado.

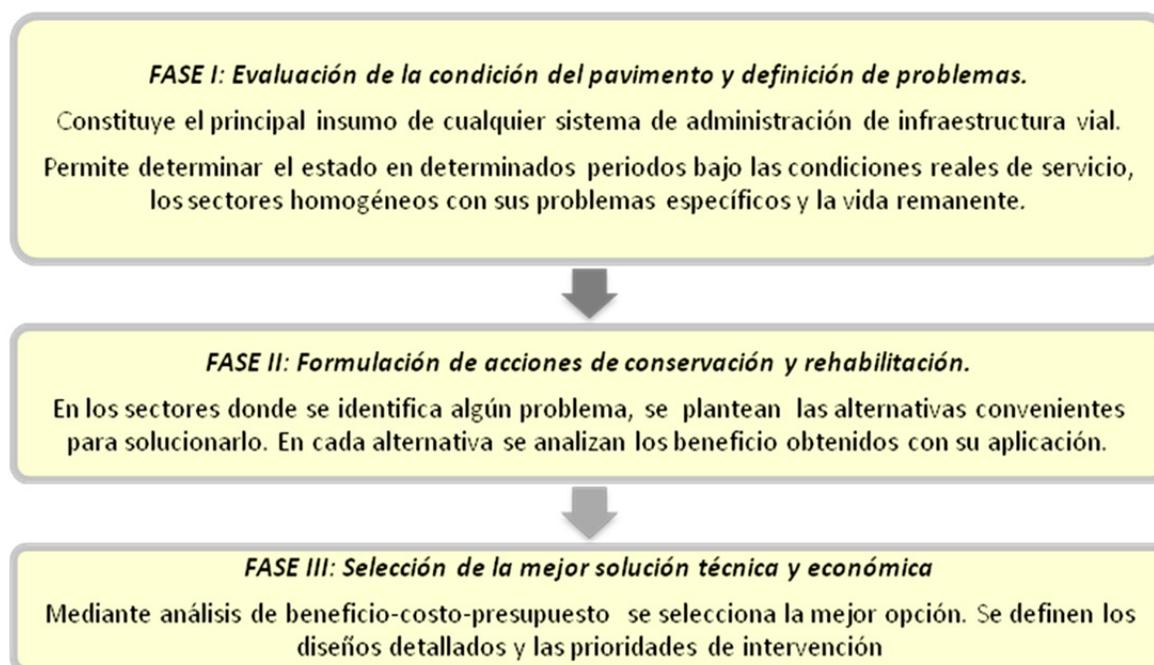


Figura 2.1 Fases de la gestión con enfoque a nivel de proyecto – AASHTO (1993)

2.2 Panorama general de la red de carreteras en México

De acuerdo con datos publicados por la Secretaría de Comunicaciones y Transporte – SCT, para el año 2010 la red nacional de carreteras en México tenía una longitud de 366341 kilómetros, con la distribución indicada en la Tabla 2.1. De la red total, cerca del 35% se encuentra pavimentada y el resto se distribuye en vías revestidas, terracerías y brechas mejoradas.

El Programa Nacional de Infraestructura 2007 – 2012 establece dentro de sus prioridades la conservación, mejoramiento y modernización de carreteras, considerando que por ellas se moviliza el 67% de la carga nacional y el 99% de los pasajeros. Al año 2010, el 81% de la red federal libre ofrecía buenas condiciones de operación y México invirtió alrededor del 2% del Producto Interno Bruto en infraestructura, y el 0.75% específicamente en el sector carretero.

Tabla 2.1 Longitud de Carreteras Nacionales en México (km)- Año2010

| RED FEDERAL | | ALIMENTADORA | RED RURAL | |
|--|-------|--------------------|---------------------|------------------|
| Básica | | | Caminos Rurales | Brechas mejorada |
| De cuota | Libre | Secundaria | | |
| 8016 | 23180 | 17464 | 170197 | 69520 |
| 48660 (13%) | | 77964 (21%) | 239717 (66%) | |
| TOTAL CARRETERAS NACIONALES: 366341 | | | | |

Datos: Secretaría de Comunicaciones y Transporte, SCT.

En cuanto a la evaluación de pavimentos y sistemas de gestión de la infraestructura de carreteras, en el ámbito nacional se tiene el siguiente panorama:

En la **red básica de cuota**, la evaluación de la condición global del pavimento se basa en un indicador de condición establecido por la SCT, en función de cinco elementos básicos: condiciones de drenaje, características de la corona de la vía, derecho de vía, señalización horizontal y señalización vertical. La evaluación se realiza por tramos de 10 Km; de manera visual y según el criterio del evaluador se otorga una calificación media a cada tramo, con una calificación máxima de 500 puntos para vías en excelente estado.

Existe un gran interés de eliminar la subjetividad y definir criterios unificados para que los operadores de las vías concesionadas evalúen los pavimentos; por ello se han ido introduciendo paulatinamente algunas especificaciones a cumplir en cuanto a profundidad de roderas, Índice de Regularidad Internacional –IRI y coeficiente de fricción.

En la **red básica libre de peaje**, la Dirección General de Conservación de Carreteras de la SCT, está implementando el modelo HDM-4 (Highway Development and Management System), para tomar decisiones de conservación e ir remplazando el “Sistema de Simulación de Estrategias de Mantenimiento Carretero – SISTER”, usado desde comienzos de los 90s.

Por su parte, el Instituto Mexicano del Transporte - IMT, propuso el “Sistema de Evaluación de Pavimentos” (Rico *et al*, 2002) para la red federal de carreteras, en sustitución del sistema SIMAP (Rico *et al*, 1990). Este sistema bien podría integrarse al HDM-4 o a cualquier Sistema de Administración de la Conservación para priorizar y presupuestar acciones de conservación. Igualmente, podría adaptarse para las carreteras federales de la red regional o para las autopistas de cuota, pues ofrece algunos criterios que eliminan la subjetividad y además involucra los siguientes elementos propios del medio mexicano:

- Para la estimación de daño al pavimento y ejes equivalentes acumulados, incorpora los autobuses foráneos de pasajeros y camiones de carga desde dos hasta múltiples ejes.
- Utiliza segmentos de estudio de 1 km de longitud.
- Es obligatoria la determinación del Índice de Regularidad Internacional -IRI y sugiere el valor de 3.5 m/km como límite para calificar una buena o mala condición del pavimento.
- Para la capacidad estructural se compara la deflexión real bajo carga medida en el campo, con la deflexión permisible o tolerable, la cual está en función de los espesores reales del pavimento al momento de la evaluación.
- Evalúa la fricción a través de coeficientes mínimos para las condiciones críticas tanto en condiciones secas, como húmedas de la superficie.

2.3 Pavimentos flexibles en servicio

Los pavimentos con superficie de rodadura en concreto asfáltico, objeto de esta investigación, se clasifican dentro de la categoría de los pavimentos flexibles, concebidos como sistemas multicapa sometidos a carga repetida del tránsito. La respuesta estructural y desempeño, depende de múltiples variables como son los procesos de deterioro, las características de la estructura, el tránsito, entre otros. Estos pavimentos se diseñan de manera tal que cada una de las capas tenga alguna función dentro de la estructura, según se describe a continuación.

La **capa asfáltica** superficial, debe proveer: suficiente **rigidez** para asumir la mayor proporción de carga; cierta **flexibilidad** para que las deformaciones por repetición se mantengan en el rango elástico; **durabilidad** para soportar adecuadamente las agresiones directas del medio ambiente; además debe garantizar una superficie **segura y cómoda** a los usuarios con características funcionales adecuadas de textura y fricción. Esta capa posee un comportamiento de tipo visco-elástico: a altas velocidades de carga se comporta elásticamente, mientras que a muy bajas tasas de carga el flujo viscoso se torna más importante.

Por su parte, **las capas granulares** internas de base y subbase (eventualmente mejoradas o estabilizadas), aportan resistencia al deterioro, estabilidad estructural y volumétrica. En el enfoque tradicional la rigidez decrece con la profundidad, pero existe el caso donde la subbase posee mayor rigidez que la base. Algunas experiencias locales han mostrado incrementos en la vida útil del pavimento con la llamada “sección invertida” (Romo y Orozco 1990; Orozco 2005).

Las capas de **subrasante y terracerías** surgieron como una necesidad de complementar la estructura de pavimento, para asumir tanto deformaciones del terreno natural, como esfuerzos transmitidos por los vehículos que circulan actualmente por las carreteras del país, los cuales alcanzan a enviar esfuerzos importantes hacia la profundidad.

El análisis de la condición estructural de los pavimentos ante las solicitaciones que le afectan puede considerarse como un problema complejo, no lineal y heterogéneo, en virtud de la interacción de gran cantidad de variables que inciden en el desempeño:

- Los **materiales** de las capas, sus propiedades mecánicas, durabilidad y especificaciones son fundamentales para conservar la integridad y minimizar las desviaciones entre los comportamientos esperados y observados de los pavimentos.
- Las **condiciones ambientales**, especialmente la temperatura y lluvias, afectan el desempeño durante la vida útil y pueden llegar a ser críticas en los procesos de deterioro.
- La **carga** dinámica impuesta por el tránsito presenta una amplia variedad en la magnitud, configuración, velocidad de aplicación y distribución de la carga con el tiempo, así como zonas preferentes de circulación o carga canalizada. Por ello resulta igualmente diversa la respuesta de la estructura, desarrollándose profundidades de influencia más superficiales

para las cargas livianas que para las cargas pesadas y acumulación de esfuerzos y deformaciones en zonas de contacto entre llantas y pavimento.

- El **terreno natural**, sus características geológicas, geotécnicas, variabilidad y problemáticas, cobran especial importancia en función de la longitud de las obras viales.
- Los métodos empleados en los **análisis, diseños y construcción**, junto con las **prácticas de mantenimiento**, influyen de manera importante en el desempeño a lo largo de su vida útil.

Para conocer el estado global de una estructura de pavimento flexible, regularmente se evalúan dos tipos de condición:

- a. La condición **estructural**, para establecer la estabilidad mecánica a través de la capacidad de soporte, la deformación permanente acumulada y la resistencia a la fatiga ante cargas repetidas del tránsito.
- b. La condición **funcional**, para definir las características de comodidad y seguridad vial ofrecidas al usuario dentro de conceptos de serviciabilidad.

Generalmente, las dos condiciones mencionadas se evalúan por separado, agrupando ciertas características medidas y observadas en un pavimento, dentro de alguna de las dos categorías. Por ejemplo, es usual considerar la regularidad superficial, la fricción y la textura superficial, dentro de la evaluación funcional; mientras que la resistencia, rigidez y espesores de las capas y algunos daños como grietas, baches y roderas, se consideran en la evaluación estructural.

Vale la pena mencionar que algunos parámetros incluidos en la evaluación estructural, también tienen sus efectos en las condiciones funcionales del pavimento; por ejemplo, la presencia de roderas, baches, depresiones y agrietamientos, si bien son el reflejo de deficiencias de carácter estructural, también afectan la serviciabilidad que ofrece un pavimento.

También se ha planteado que la evolución de un deterioro funcional como la regularidad superficial, puede tener componentes que dependen de la pérdida de capacidad estructural por fatiga y deformación permanente, los efectos ambientales y las prácticas de conservación aplicadas históricamente (Paterson, 1987).

En el año 2004, el programa “National Cooperative Highway Research Program – NCHRP” de Estados Unidos, amplió el panorama de evaluación global del pavimento según se indica en la Tabla 2.2, para involucrar las condiciones de drenaje, el mantenimiento, la durabilidad de los materiales ante efectos ambientales y conceptos asociados con procesos de deterioro.

En esta metodología, un parámetro puede considerarse dentro de diferentes categorías de evaluación de la condición; por ejemplo, las roderas y las ondulaciones son indicadores de evaluación tanto estructural como de durabilidad.

Tabla 2.2 Evaluación de la condición global de pavimentos flexibles

| EVALUACIÓN | PARÁMETROS |
|----------------------|--|
| ESTRUCTURAL | Grietas: fatiga, longitudinales, transversales y reflexión |
| | Roderas |
| | Ondulaciones |
| | Resistencia y rigidez: Módulo elástico de capas |
| FUNCIONAL | Fricción y Textura superficial |
| | Regularidad superficial - IRI |
| DRENAJE | Desintegración de capa asfáltica |
| | Bombeo en superficie |
| DURABILIDAD | Pérdida de agregados |
| | Roderas |
| | Ondulaciones |
| | Fisuras en bloque |
| | Exudación |
| | Desintegración o erosión de capas granulares |
| | Contaminación de capas granulares |
| MANTENIMIENTO | Parches deteriorados |
| OTROS | Acotamientos, derechos de vía, controles de tránsito. |

Adaptada de ARA, Inc. y ERES Consultants Division NCHRP-TRB-NRC-2004.

2.4 Técnicas de auscultación

Para evaluar la condición global de un pavimento, es necesario desarrollar varias etapas, iniciando con la auscultación en campo para recopilar datos representativos de la condición real que exhibe, considerando la aplicación de técnicas tanto destructivas como no destructivas.

La auscultación destructiva fue por muchos años la única opción con que se contaba, excavando pozos a cielo abierto o realizando sondeos en la estructura del pavimento, siendo posible medir directamente los espesores de las capas e identificar daños estructurales de difícil detección en superficie. En los pozos adicionalmente pueden efectuarse pruebas de densidad y de resistencia en campo, así como recuperación de muestras de los materiales de las capas para su caracterización mediante pruebas en laboratorio. Estas técnicas tienen sus desventajas pues requieren demasiado tiempo de ejecución, tienen gran impacto sobre la circulación del tránsito, resultan costosas por la destrucción del pavimento y en la restitución de los pozos no se obtienen las condiciones originales.

En la actualidad, se ha intensificado el uso de **métodos No Destructivos – ND**, por la rapidez, facilidad y versatilidad con que permiten recolectar información relevante para evaluar carreteras. Las prácticas más comunes de auscultación ND para recopilar información son:

La medición de la alteración del perfil longitudinal expresado a través del Índice de Regularidad Internacional – IRI; puede registrarse de manera muy eficiente mediante equipos de alto rendimiento dotados con sensores láser, acelerómetros y transductores de velocidad y distancias.

La medición de la resistencia al deslizamiento, a través de la textura superficial y la fricción; la primera puede evaluarse eficientemente mediante emisión de rayos láser con vehículo en movimiento y la segunda, midiendo el coeficiente de rozamiento entre el pavimento y un neumático de prueba.

La inspección visual con recorridos en la vía a pie o con equipos de alto rendimiento dotados de cámaras de video y sistemas globales de ubicación – GPS, para registrar los daños apreciables en la superficie del pavimento o aspectos relevantes sobre el drenaje, los acotamientos y el entorno. La interpretación de las imágenes digitales registradas con las cámaras, puede realizarse mediante software especializado, o en su defecto con arduo trabajo de gabinete por parte de analistas. Para el **inventario de daños**, puede obtenerse un panorama muy completo y detallado en el campo, utilizando alguna de las metodologías propuestas para esos fines: la planteada por el Instituto Mexicano del Transporte (1991), el Cuerpo de Ingenieros de los Estados Unidos (2001), el Manual Centroamericano de Mantenimiento de Carreteras (Comitran, 2001), el Catálogo de Deterioros de pavimentos flexibles del Consejo de Directores de Carreteras de Iberia e Iberoamérica (2002), el Manual de Identificación del Deterioro para Pavimentos de Larga Duración (Miller y Bellinger 2003), entre muchas otras.

Auscultación con **radar de penetración superficial**, denominado comúnmente como georadar o GPR (por sus siglas en inglés). Estas pruebas se utilizan para la medición continua de espesores de las capas del pavimento o para identificar características no detectables en superficie como instalaciones subterráneas, agrietamientos internos, oquedades, entre otras. Por el carácter indirecto y no destructivo de las pruebas, no es posible tener contacto directo con los materiales para su identificación. Además, sólo permiten registros confiables hasta profundidades del orden de un metro y aunque tienen altos rendimientos en campo, requieren grandes esfuerzos en gabinete para la interpretación de los registros.

Las pruebas con GPR se basan en la emisión de ondas electromagnéticas a través del pavimento mediante una antena; en las fronteras donde existan cambios de material, las ondas generan ecos que pueden detectarse mediante otra antena receptora; con base en los tiempos de arribo y la fuerza de los ecos se estiman espesores de capas y algunas otras propiedades que dan indicios del tipo de material. La información queda registrada en forma de imágenes de radar a lo largo del corredor vial auscultado, permitiendo el registro continuo de espesores de capas; el

análisis gráfico resulta útil para identificar los sistemas estructurales presentes a lo largo de un corredor y para definir sectores homogéneos en función de las variaciones que se observen.

La medición de deformaciones permanentes en las huellas de circulación de los vehículos, denominadas roderas o ahuellamiento. Pueden registrarse de manera muy eficiente mediante equipos de alto rendimiento dotados con sensores láser; los equipos más modernos incluyen sistemas de adquisición de datos que facilitan el almacenamiento y procesamiento en línea; aquellos que cuentan con acelerómetros y transductores de velocidad y distancias, pueden registrar simultáneamente otros indicadores funcionales como el IRI y la textura superficial.

Mediciones basadas en propagación de ondas: Se mide el tiempo de viaje de ondas generadas por impulsos aplicados sobre la estructura de pavimento. En pruebas con Analizador Sísmico Portátil de Pavimentos – PSPA, se mide la velocidad de propagación de ondas de compresión de alta frecuencia; por su parte, las pruebas de Análisis Espectral de Ondas de Superficie – SASW, registran la dispersión de ondas Rayleigh propagadas con distinta frecuencia y velocidad (Heisey- 1982 y Nazarian *et al.* entre 1983 y 1986). En virtud de la magnitud de la carga usada para la generación de ondas, su uso se considera limitado a determinar módulos elásticos de cada capa a bajos niveles de deformación.

Medición de deflexiones en la superficie: Su determinación se basa en simular el efecto de las cargas de tránsito sobre el pavimento, midiendo la respuesta de desplazamientos verticales generada; la magnitud y forma de los desplazamientos se encuentra fuertemente asociada con la rigidez de las capas y sus espesores, permitiendo, por tanto deducir parámetros mecánicos. Uno de los fundamentos conceptuales del sistema de gestión vial mexicano, es la aceptación de que “la deficiencia estructural puede correlacionarse con alguna medida hecha desde la superficie del pavimento. La deflexión parece ser el concepto que mejor sirve para estos fines, pues su magnitud mide el defecto estructural, aunque no lo analice ni lo localice,” (Rico *et al.* 1998).

Dentro de las diferentes posibilidades para la medición de deflexiones, está el equipo Dynaflect, el cual impone una carga dinámica liviana cuyo periodo de aplicación intenta simular la velocidad de los vehículos. Sin embargo, se considera que sus resultados están limitados debido a los bajos niveles de carga que transmite y la poca profundidad de influencia que se alcanza.

En contraste, se ha encontrado que los métodos de deflexión con carga pesada son más apropiados para la evaluación estructural del pavimento. Existen equipos con carga estática como la Viga Benkelman y el Deflectógrafo Lacroix, o equipos con carga dinámica como el deflectómetro rodante de alta velocidad – RDT y los deflectómetro de impacto tipo Falling Weight Deflectometer (FWD) o Heavy Weight Deflectometer (HWD). La magnitud y tiempo de aplicación de la carga impuesta por los tres últimos, ha permitido simular satisfactoriamente el efecto del tránsito sobre el pavimento; el FWD y HWD requieren detener el equipo para realizar las pruebas mientras que el RDT es el método más rápido para recolectar datos en campo puesto que el equipo va en movimiento.

En México existe una tendencia creciente hacia la aplicación de pruebas con FWD y HWD, gracias a la disponibilidad de equipos, la rapidez y facilidad de medición; en el capítulo 3 se describen en detalle tales pruebas, dada su relevancia para esta investigación doctoral.

3 COMPONENTES DE LA EVALUACIÓN ESTRUCTURAL

En la práctica común, la evaluación estructural de un pavimento se realiza en función de tres elementos primordiales: i) **los espesores y materiales** de las capas que lo conforman; ii) el **comportamiento mecánico** del pavimento y iii) la magnitud y severidad del **deterioro estructural** que exhibe.

El análisis integral de los elementos mencionados, permite definir **los sectores homogéneos de comportamiento**, identificando claramente los problemas existentes y el nivel de afectación en cada sector. En aquellos casos en que se cuenta con información sobre pronósticos de tránsito, leyes de fatiga de los materiales y modelos de deterioro, también es posible estimar la **vida remanente** del pavimento en cada sector. A continuación, se describen los aspectos más relevantes de cada componente de la evaluación estructural.

3.1 Espesores y materiales de las capas

Es importante definir con la mejor precisión posible, el espesor y el tipo de materiales que conforman cada una de las capas del pavimento; si no se cuenta con registros históricos confiables, debe recurrirse a campañas de auscultación en campo. Lo ideal es combinar las pruebas no destructivas de GPR con sondeos y pozos a cielo abierto recuperando muestras para pruebas de laboratorio y, efectuar pruebas de densidad y resistencia en campo. De este modo se obtiene tanto el registro continuo de los espesores, como la caracterización directa de los materiales de las capas.

Integrando esta información, es posible identificar los sistemas estructurales presentes y la variación en los tipos y propiedades de los materiales de las capas a lo largo de un corredor, como por ejemplo tramos con capas estabilizadas o rigidizadas; igualmente pueden determinarse parámetros de los materiales y detectar sitios eventuales con deficiencias de la calidad exigida (granulometría, durabilidad, compactación, entre otras).

3.2 Evaluación del comportamiento mecánico del pavimento

Considerando que cada impulso de carga generado por los vehículos sobre el pavimento se transfiera gradualmente hacia la profundidad a través de las capas que lo conforman, el énfasis en el estudio del comportamiento de los pavimentos se ha dado fundamentalmente hacia los **esfuerzos y deformaciones** inducidos en cada repetición de carga a través de las llantas de un vehículo y **la resistencia y rigidez de las capas** del pavimento que soportan la carga.

3.2.1 Esfuerzos y deformaciones en los pavimentos

El comportamiento mecánico de un pavimento se puede evaluar comparando los valores estimados en puntos críticos del pavimento, con los límites admisibles. Por muchos años se aceptó que la respuesta de un pavimento flexible ante una solicitación determinada es función de esfuerzos, deformaciones y deflexiones, considerando que los cuatro indicadores más significativos del comportamiento son la deflexión superficial, la deformación por tensión en la carpeta asfáltica y los esfuerzos y deformaciones de compresión en la subrasante. Los dos primeros están relacionados con el agrietamiento del concreto asfáltico por fatiga, mientras los dos últimos con las deformaciones permanentes en el pavimento.

Los modelos mecanicistas más recientes aceptan estos mismos criterios, adicionando el agrietamiento térmico y el Índice de Regularidad Internacional (IRI). En la Figura 3.1 se ilustran algunos ejemplos de variables críticas de respuesta que pueden considerarse para el análisis, las cuales se mencionan en la guía AASHTO-2004 (ARA, Inc. & ERES CD, 2004) y se describen a continuación; estas variables pueden obtenerse por medio de las leyes de la fatiga de los materiales.

- La deformación por tensión (ϵ_t) en los planos inferior y superior de la capa asfáltica, relacionada con: *agrietamiento por fatiga* ante carga repetida del tránsito, con propagación ascendente o descendente; *agrietamiento térmico* con propagación descendente.
- El esfuerzo y deformación vertical por compresión dentro de la capa asfáltica, relacionadas con *la deformación permanente acumulada* de la carpeta.
- El esfuerzo y deformación vertical por compresión dentro de las capas granulares, relacionadas con la deformación permanente acumulada de dichas capas.
- El esfuerzo y deformación vertical por compresión en el plano superior de la subrasante, asociada con la deformación permanente acumulada.

A estas variables críticas, se suma la deflexión superficial, la cual se ha asociado directamente con el agrietamiento del concreto asfáltico por fatiga.

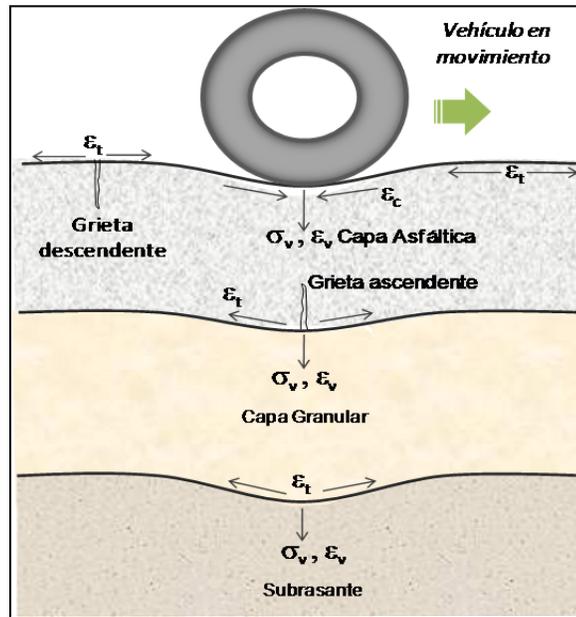


Figura 3.1 Respuesta del pavimento ante carga – variables críticas

Para modelar la respuesta del pavimento ante carga, se han desarrollado planteamientos teóricos o teórico-experimentales simplificados, apoyados fundamentalmente en la teoría de visco-elasticidad y la elasticidad. Inicialmente Boussinesq en 1885 propone una aproximación para determinar el estado de esfuerzos a cualquier profundidad en una masa de suelo lineal, elástico, isótropo y homogéneo bajo una carga concentrada; en ello se apoyó Burmister para proponer en 1945 los mismos principios, pero introduciendo transformadas de Fourier para considerar la estratificación y las propiedades de los materiales.

El uso de análisis multicapa desarrollado por Burmister (1945) para representar la respuesta de un pavimento solo se difundió de manera extendida hasta 1962, en la primera conferencia internacional de diseño estructural de pavimentos asfálticos. Westergaard, Odemark y otros, presentaron la extensión del modelo a sistemas multicapa con distintas condiciones de frontera.

Actualmente se utilizan herramientas computacionales para programar ecuaciones diferenciales que conduzcan a la estimación de esfuerzos, deformaciones y deflexiones a las que está sometido el pavimento y la subrasante bajo las solicitaciones de carga impuestas por el tránsito. Se ha observado que los modelos basados en teoría elástica multicapa aún poseen suficiente rigor teórico y velocidad de cómputo para análisis lineales en pavimentos con estratos rígidos profundos donde resulta válida la hipótesis tradicional que considera al suelo de cimentación como una capa de espesor semi-infinito.

Para el análisis de esfuerzos y deformaciones en pavimentos con capas no ligadas cuyo comportamiento no es lineal-elástico, los métodos basados en elementos finitos suelen resultar más convenientes, aunque requieren alto costo computacional al incrementar la complejidad del problema y la cantidad de variables consideradas. Dentro de los programas de cómputo

desarrollados para modelar el comportamiento de los pavimentos, se ha visto que los más versátiles son aquellos que permiten modelar sistemas multicapas con comportamiento que pueden variar entre lineal, no lineal y visco-elástico, bajo sistemas de carga con ejes múltiples (Garnica y Correa, 2004). De todas maneras, aunque se quiera refinar en los análisis, Ullidtz (1999) indicó que “incluso los modelos teóricos más sofisticados, como los de elementos finitos dinámicos, tri-dimensionales visco-elasto-plásticos, caen en simplificaciones tales como no considerar la naturaleza particulada de los materiales para pavimentos”.

Para efectos de diseño, los métodos racionales han introducido conceptos complementarios a los análisis de esfuerzo y deformación, asociados con la reología de los asfaltos, los módulos dinámicos, la mecánica del continuo, las leyes de fatiga de los materiales, entre otros. Estos métodos reconocen dos tipos de falla: por **deformaciones permanentes acumuladas** y por **fatiga** de la carpeta asfáltica ante cargas repetidas del tránsito, especialmente aquellas de gran intensidad y/o frecuencia.

Actualmente los métodos mecánico-empíricos, intentan aportar una idea más completa del comportamiento mecánico del pavimento ante el efecto del tránsito y las condiciones ambientales para poder predecir la evolución del deterioro y los eventuales mecanismos de falla mediante un conocimiento más profundo de los materiales. Por ejemplo, se propone que los módulos de resiliencia de las capas no se estimen por correlación con otros indicadores, sino experimentalmente mediante las relaciones esfuerzo y deformación. Aunque estos métodos asumen las hipótesis simplificadoras de las teorías de la elasticidad y la visco-elasticidad, involucran mayor observación en campo; por lo mismo requieren calibración local con los comportamientos reales observados para hacer extensiva su aplicación (Garnica y Correa 2004).

El estudio de Paterson (1987), auspiciado por el Banco Mundial, constituye una aproximación hacia análisis mecánico-empíricos cuyos modelos de deterioro y criterios de falla constituyen la base para el sistema de administración de carreteras HDM-4. Por su parte, la guía AASHTO para el diseño de pavimentos por métodos mecánico-empíricos (MEPDG, por sus siglas en inglés), plantean modelos matemáticos para predecir la evolución con el tiempo y la falla por deterioro estructural tipo roderas y agrietamiento tanto térmicos como de fatiga. Estos modelos tienen su ámbito de validez dentro de condiciones similares para las cuales fueron desarrollados; su aplicación hacia otras condiciones requiere observación, calibración y validación rigurosa.

3.2.2 Resistencia y rigidez de las capas

Con el propósito de caracterizar las capas que conforman una estructura de pavimento, históricamente se han propuesto diferentes parámetros e indicadores mecánicos, todos con mayor o menor soporte en la literatura técnica. También ha habido intentos de establecer correlaciones entre dichos parámetros, sin encontrar muy buenos resultados puesto que cada parámetro mide atributos diferentes y solamente podrían relacionarse en la medida en que se evalúen pavimentos con similares características y niveles de resistencia. A continuación se presentan los indicadores y parámetros de resistencia y rigidez más usados en la práctica.

i) **El Valor Relativo de Soporte, VRS.** Constituye una de las formulaciones netamente empíricas apoyadas en propiedades físicas de los materiales. Aunque este concepto no refleja la resistencia de las capas ante las cargas de tránsito, por muchos años se consideró como un indicador de la capacidad de soporte en pavimentos.

ii) **El Número Estructural (SN)** propuesto por la AASHTO como parámetro de la resistencia en el método de diseño en la versión del año 1993. Su determinación se basa en el método de espesor equivalente, ponderando la capacidad de soporte aportada por cada capa según sus espesores y coeficientes de resistencia, los cuales están en función de los materiales y de las condiciones de drenaje en las capas granulares. En su estimación también intervienen datos de tránsito, parámetros estadísticos, el módulo efectivo de la subrasante y la pérdida de serviciabilidad entre el año inicial y final del periodo de diseño considerado.

Paterson (1987) propuso estimar el SN con base en pruebas de deflexión, metodología que fue adoptada en el sistema de administración de carreteras HDM-4. Por su parte Hoffman (2003) propuso otra aproximación mecánico-empírica conocida como el método YONAPAVE, a partir de cuencas teóricas de deflexión y del modelo de Hogg, donde se representa el pavimento como una placa delgada horizontalmente infinita, apoyada sobre una capa elástica, homogénea e isotrópica. Gómez *et al* (2007) señalan que el valor de SN en sí no es representativo de la capacidad de soporte, pues un tramo puede tener un SN bajo sin que ello necesariamente represente una condición inadecuada.

iii) **La relación de Poisson.** Ante carga axial, se define como la relación entre la deformación lateral respecto a la deformación axial (ϵ_l / ϵ_a), según se ilustra en la Figura 3.2. Su determinación se realiza mediante pruebas de laboratorio y constituye uno de los parámetros de entrada a los modelos de respuesta usados en los métodos de diseño mecánico-empíricos.

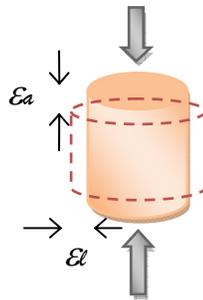


Figura 3.2 Relación de Poisson

Para efectos prácticos de análisis, suele asumirse valores típicos constantes de las relaciones de Poisson para cada capa del pavimento, considerando que este parámetro tiene intervalos de variación muy estrechos, con límites bien definidos para cada tipo de material como se aprecia en la Tabla 3.1. En varios estudios se ha mencionado que esta práctica no tiene efectos significativos en la estimación de módulos, esfuerzos, deformaciones y desplazamientos en pavimentos (ARA Inc. y ERES C.D., 2004; Huang, 2003; Ullidtz, 2000 y Uzan 1994).

iv) **Los módulos de capa.** Para efectos de diseño de pavimentos, los módulos de capa representan insumos necesarios y pueden determinarse en laboratorio tanto para las capas asfálticas (*módulo dinámico*), como para las granulares (*módulo resiliente*). En el primer caso, se somete una muestra cilíndrica de concreto asfáltico a la repetición de pulsos de esfuerzo cíclico en compresión simple, bajo las condiciones de temperatura y velocidad de carga representativas de la vía en operación; el módulo dinámico se calcula como la relación entre el esfuerzo aplicado y la deformación elástica unitaria en cada ciclo de carga.

En cuanto al módulo resiliente, Seed *et al* (1963) lograron avances importantes en su definición para suelos finos y materiales granulares, encontrando fuertes relaciones con el estado de esfuerzos. Este módulo se determina mediante prueba triaxial, aplicando esfuerzo desviador cíclico y presión de confinamiento constante; el módulo se calcula como la relación entre el cambio en el esfuerzo desviador y el cambio en la deformación elástica unitaria después de muchos ciclos de carga según se ilustra en la Figura 3.3. De este modo, sólo se consideran las deformaciones recuperables y no aquéllas permanentes bajo carga repetida.

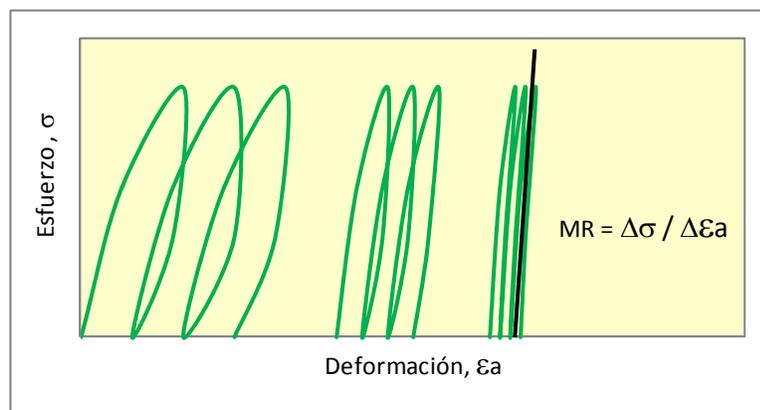


Figura 3.3 Módulo resiliente a partir de prueba cíclica de carga

Para el caso de pavimentos a rehabilitar, los módulos de capa proporcionan una medida de la competencia estructural de las capas bajo las condiciones ambientales reales y pueden determinarse *in situ* a partir de pruebas no destructivas de deflexión por impacto.

Aunque se ha intentado establecer relaciones entre los módulos retro calculados y los estimados en laboratorio, no existe aún resultados concluyentes y las diferencias encontradas se han atribuido principalmente a las distintas condiciones en los estados de esfuerzos propias de las pruebas de campo y de laboratorio (FHWA, 2006). Mediante la revisión de algunos casos reportados en carreteras mexicanas, se encuentra que los módulos estimados a partir de pruebas de laboratorio resultan entre 13% y 20% menores que los estimados con pruebas de campo. En la Tabla 3.1 se incluyen algunos valores de referencia para dar una idea de los órdenes de magnitud de módulos en cada capa.

Tabla 3.1 Valores típicos de parámetros mecánicos del pavimento

| CAPA | Módulo de Elasticidad (k/cm^2) | | | | | | Rel. Poisson |
|--------------------------|------------------------------------|-------|--------|------------|----------------|---------------|--------------|
| | Proyecto NCHRP* | | | ASTM D5858 | Laboratorio ** | Campo ** | ASTM D5858 |
| | Bajo | Medio | Alto | | | | |
| Concreto asfáltico | 21300 | 35500 | 106500 | 35500 | 10740 a 28433 | 12390 a 35426 | 0.3 a 0.4 |
| Base tratada con cemento | 17750 | 42600 | 71000 | 42600 | | | |
| Base tratada con asfalto | 7100 | 17750 | 35500 | | | | |
| Base granular | 1060 | 2130 | 2840 | 2130 | 1847 | 2200 | 0.2 a 0.4 |
| Subbase granular | 570 | 1060 | 1770 | 1060 | 1268 | 1500 | |
| Suelo - cemento | 3550 | 5320 | 7100 | 3550 | | | 0.1 a 0.3 |
| Subrasante granular | 500 | 850 | 1420 | | 904 | 1000 | |
| Subrasante fina | 210 | 350 | 500 | 500 | | | 0.25 a 0.45 |

Fuente: *ARA, Inc.; ERES CD (2004); ASTM D5858 (2003); **Coconal.

3.2.3 Estimación de módulos de capa a partir de pruebas de deflexión

Las pruebas no destructivas de deflexión por impacto consisten en aplicar sobre el pavimento un impulso de carga controlada (Q), cuya magnitud varía entre 0.7 y 16 ton (6.7 y 156 kN) en el equipo FWD y entre 2.7 y 24.5 ton (26 a 240 kN) en el equipo HWD; en cualquier caso, la magnitud de la carga aplicada debe ser representativa de los vehículos pesados que circulan por la vía. La carga se aplica en caída libre sobre una placa circular colocada en la superficie del pavimento y dependiendo del equipo empleado, la placa puede ser rígida (Dynatest) o segmentada (KUAB); Croveti *et al* (1989) analizaron el efecto de los dos tipos de placa en las respuestas registradas y en los módulos de capa para pavimentos rígidos y flexibles.

El pulso de fuerza transmitido al pavimento tiene una duración de 20 a 60 milisegundos y genera una curva base en el dominio del tiempo, con comportamiento tipo haversine o “half-sine”, como la ilustrada en la Figura 3.4.

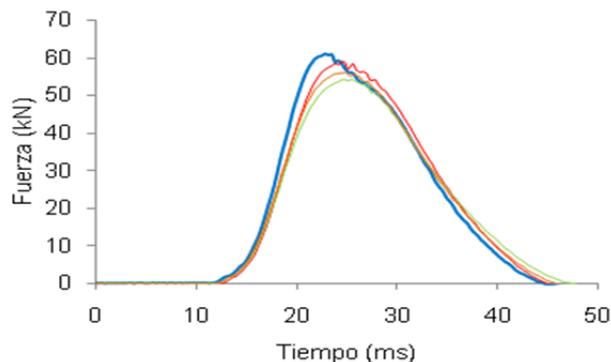


Figura 3.4 Pulso de fuerza transmitido en pruebas de deflexión

La respuesta en términos de deflexiones del pavimento, se registra por medio de sensores localizados radialmente a diferentes distancias del eje de aplicación de carga, según se ilustra en la Figura 3.5. Los sensores pueden ser geófonos o LVDTs, los cuales tienen la capacidad de registrar deflexiones máximas de 2 mm y 5 mm respectivamente, dependiendo del equipo empleado. Los valores registrados se grafican en función de la ubicación de cada sensor, para obtener finalmente el perfil de desplazamientos verticales (D_1, D_2, \dots, D_n), o cuenca de deflexión. En la norma ASTM 4694 o en la traducción de Pérez *et al* (2004), se pueden consultar mayores detalles operativos sobre estas pruebas.

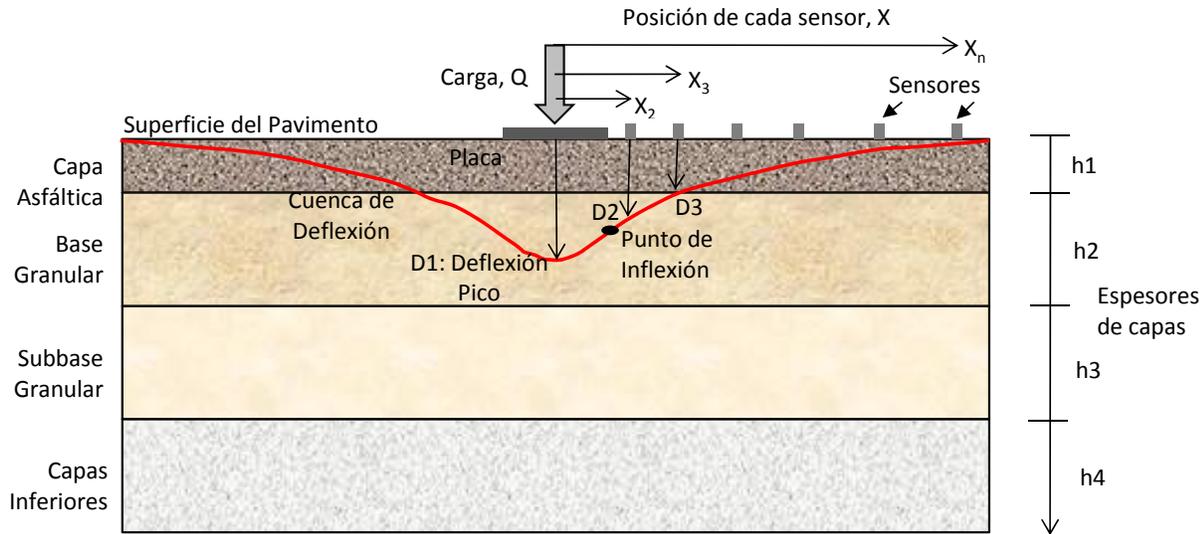


Figura 3.5 Prueba de deflexión por impacto y cuenca de deflexión.

El valor máximo o pico - $D_{m\acute{a}x}$, corresponde a la deflexión registrada en el sensor ubicado en el sitio de aplicación de la carga y representa la deflexión de toda la estructura del pavimento. Las deflexiones medidas cerca del eje de carga se han asociado con la rigidez relativa de las capas superiores de la estructura del pavimento (Shahin, 2005 y Goktepe, *et al* 2006); así mismo, las deflexiones en la parte media del cuenco reflejan la rigidez relativa de las capas intermedias, mientras que las deflexiones más alejadas del eje de carga se han relacionado con la rigidez de las capas inferiores (Gopalakrishnan, 2010).

Durante la ejecución de las pruebas se deben documentar las condiciones ambientales y la temperatura del pavimento, puesto que los parámetros e indicadores derivados son representativos de las condiciones predominantes en esos momentos.

En particular, la rigidez de la capa asfáltica depende de la temperatura; en general, a mayor temperatura menor rigidez y mayores son las deflexiones registradas; sin embargo, cuando la temperatura es muy alta, comienzan a intervenir las propiedades viscosas del asfalto y la deformación plástica se vuelve más importante, con la consecuente disminución de la respuesta elástica y, por tanto, de las deflexiones (INVIAS 2008). Por ello, se aplica un factor de corrección para convertir los valores de deflexión observados a valores a la temperatura estándar. Tal

corrección se efectúa en aquellos sensores que capturan las características de la capa asfáltica; Shahin (2005) y Goktepe *et al* (2006) identificaron que las deflexiones registradas en los sensores ubicados hasta 0.6 m del eje de carga, son sensibles al cambio de la temperatura.

Por otra parte, es deseable efectuar las pruebas fuera del área de influencia de estructuras de drenaje y de zonas deterioradas; de ser el caso, es necesario reportar la ubicación, el tipo de daño y severidad, y el tipo de obra (alcantarilla, puentes, etc.), para ayudar a explicar los hallazgos posteriores en sitios específicos; se ha encontrado que estas características pueden llegar a tener mayor incidencia en la respuesta de deflexiones del pavimento, que la misma rigidez de las capas.

Como las pruebas se realizan en un instante específico de la vida útil del pavimento, no son indicativas de las deformaciones a largo plazo con carga repetida (Rico *et al*, 1998). Sin embargo, mediante campañas sistemáticas y periódicas de auscultación y experimentación, se pueden identificar los cambios de capacidad estructural que sufre el pavimento con el tiempo y asociarlos con las repeticiones de carga que han soportado durante el periodo analizado.

La realización de pruebas de deflexión debidamente espaciadas a lo largo de un corredor vial, permite identificar la variación de la capacidad estructural en toda su longitud y en algunos casos, ver la necesidad de complementar la información con auscultación destructiva.

En particular, para el análisis y la estimación de módulos de capa a partir de las cuencas de deflexión, suelen presentarse tres posibilidades:

- a) Ecuaciones de regresión
- b) Cálculo directo
- c) Cálculo inverso o retrocálculo

En este trabajo sólo se abordan las técnicas de retrocálculo, las cuales varían según el tipo de análisis, el modelo de respuesta y el algoritmo de optimización utilizado. En la literatura técnica se encuentran discusiones detalladas sobre diferentes métodos de retrocálculo usados entre los años 1983 y 2008, y los comparan en términos de precisión, consumo computacional, detalles de cálculo y requerimientos de las bases de datos (Lytton 1989; Uzan 1994; Goktepe *et al* 2005; Goel y Das 2008).

Se encuentra que la **precisión** de los análisis de retrocálculo es sensible al tipo y cobertura del análisis de respuesta del pavimento, mientras que la **eficiencia** en términos de tiempo, depende de la técnica de optimización, considerada en general como un asunto complementario. Para agilizar el proceso y mejorar los niveles de confiabilidad, es necesario seleccionar correctamente el algoritmo de optimización que permita superar los problemas de convergencia, así como obtener velocidad y precisión en los análisis.

En la práctica tradicional, el problema de retrocálculo de módulos se reduce a un principio básico de acción (carga aplicada) – reacción (respuesta de deflexiones del pavimento), ambos relacionados mediante alguna ley o modelo convencional de respuesta del pavimento.

$$\text{Deflexiones} = f(\text{Carga, Espesores, Materiales, Módulos})$$

Se asume la hipótesis de que existe una combinación de módulos de capa que generan unas respuestas de deflexión teóricas muy aproximadas a las medidas con deflectómetro; la complejidad de los análisis aumenta con la cantidad de capas del pavimento. Para realizar los estimativos de manera eficiente, tradicionalmente se utilizan programas de cómputo con la secuencia ilustrada en la Figura 3.6, acoplados con un proceso iterativo de ensayo y error.

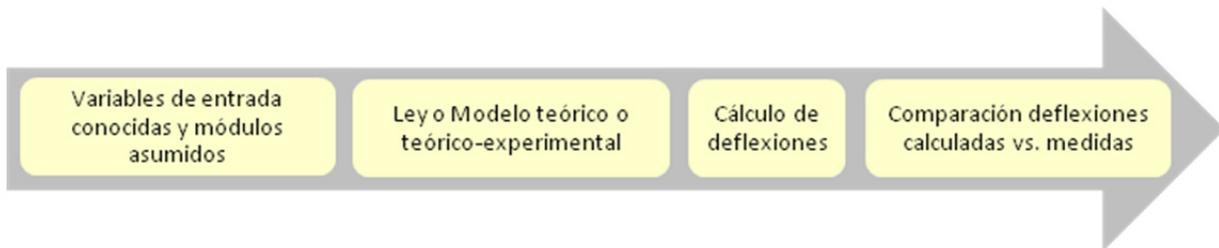


Figura 3.6 Solución tradicional al problema del cálculo inverso

En principio, se asumen valores de “módulos semilla” para cada capa y se calculan las deflexiones a partir de datos de la estructura del pavimento; luego se comparan las deflexiones calculadas teóricamente con las medidas, y se verifica el nivel de aproximación entre ellas; a través de iteraciones sucesivas se van ajustando los módulos con rutinas de identificación de parámetros y se recalculan las deflexiones hasta lograr aproximaciones con cierto margen de tolerancia. Algunos programas contienen intervalos preestablecidos de módulos para evitar llegar a soluciones irreales, pero con esta práctica se limita de algún modo la convergencia de las soluciones hacia dichos intervalos.

Otra forma de aproximarse a la solución, es mediante el uso de programas de cómputo donde las deflexiones medidas se comparan directamente con conjuntos de cuencas de deflexión almacenados en la base de datos, generadas de manera teórica o sintética. En este caso, se supone que los parámetros de resistencia y rigidez usados para calcular la cuenca teórica que mejor coincide con la medida en el terreno, corresponden a la solución buscada.

El nivel de aproximación o convergencia entre lo medido y lo estimado, generalmente se evalúa mediante la minimización de una función de error; algunas de las expresiones más comúnmente usadas son:

La raíz del error cuadrático medio (RMSE). Se considera que la convergencia es adecuada si el RMSE es 2 % como máximo.

$$RMSE = 100 * \sqrt{\frac{1}{n} * \sum_{i=1}^n \left[\frac{(Dmed_i - Dcalc_i)}{Dmed_i} \right]^2}$$

Donde:

$Dmed_i$ = deflexión medida en el sensor i

$Dcalc_i$ = deflexión calculada en el sensor i

n = número de sensores usados para medir la cuenca

El error absoluto, (AASE). La tolerancia en el error AASE depende del número de sensores (máximo 14% para 7 sensores).

$$AASE = 100 * \sum_{i=1}^n \left| \frac{(Dmed_i - Dcalc_i)}{Dmed_i} \right|$$

El error medio absoluto (EMA):

$$EMA = \frac{100}{M} * \sum \left| \frac{(Dmed_{ij} - Dcalc_{ij})}{Dmed_{ij}} \right|$$

Siendo:

$Dmed_{ij}$ = deflexión medida en el sensor i para la prueba j

$Dcalc_{ij}$ = deflexión calculada en el sensor i para la prueba j

M = La cantidad de pruebas multiplicada por el número de sensores.

El EMA reduce el efecto de valores atípicos o dispersos (LDC Inc. 1996), lo cual representa una ventaja, teniendo en cuenta la variedad de respuestas que se pueden encontrar en el pavimento en función de las condiciones ambientales, estructurales, de deterioro, entre otros.

En cualquier caso, la solución obtenida no es única ni exacta pues depende del set de módulos semilla introducidos por el usuario, de modo que varias combinaciones de módulos pueden producir la misma cuenca de deflexiones y por tanto, el mismo error (Mehta y Roque 2003); se requiere entonces, buen criterio del analista para seleccionar la solución más razonable. En ese sentido, los mismos autores proponen que como la rigidez del pavimento está asociada con la forma de la cuenca, puede ser más conveniente hacer coincidir algún indicador de la curvatura de las cuencas medidas y calculadas, para obtener valores más representativos de los módulos.

Desde el punto de vista del modelo de respuesta utilizado, en la práctica común se utilizan técnicas de retrocálculo bajo dos enfoques diferentes: **estáticos y dinámicos**. Mediante estas dos aproximaciones es posible realizar análisis no lineales (Uzan, 1994 y Ullidtz, 2000), pero el costo y complejidad computacional se incrementa considerablemente; por ello, regularmente se

asume la hipótesis simplificadora de linealidad de los materiales para solucionar el problema de manera eficiente, sacrificando de alguna manera la precisión.

Las aproximaciones **estáticas** se apoyan en la teoría elástica multicapa, la cual constituye la base de los estimativos propuestos en la guía ASTM D5858; los trabajos de Wiseman *et al* (1977), Ullidtz (1999 y 2000), Biswas y Pellinen (2007) y Seo *et al* (2009), constituyen algunos ejemplos aplicados. A pesar de su amplia utilización, la mayoría de estas aproximaciones tienen restricciones para estimar los módulos elásticos de las capas en los siguientes casos (INVIAS, 2008 y ASTM D5858, 2003):

- i. En estructuras de pavimento donde la rigidez de las capas no necesariamente decrece con la profundidad, como sería el caso de secciones invertidas.
- ii. Cuando existe una capa de base débil que no provee apoyo suficiente para que la capa asfáltica soporte las deformaciones inducidas por los esfuerzos de tracción, con la posibilidad de desarrollar fisuras por fatiga; en este caso, el cuenco de deflexión es muy cerrado, con radio de curvatura pequeño; si la $D_{m\acute{a}x}$ no es muy alta, la estructura total puede preservar la integridad de las capas inferiores.
- iii. Cuando se presentan deformaciones permanentes que afectan la estructura por posible insuficiencia de espesores o mala calidad de los materiales que la constituyen; en los casos más críticos, es posible que estas depresiones estén acompañadas de grietas por fatiga.
- iv. Cuando la capa superficial es muy delgada o cuando existe dentro de la estructura, una capa gruesa sobre una más delgada.
- v. Dado que la teoría elástica no considera discontinuidades existentes en el pavimento, existen limitaciones para estimar módulos a partir de cuencas de deflexión medidas en zonas afectadas por agrietamientos y otros daños.

En todos los casos mencionados, la diferencia entre las deflexiones medidas y calculadas puede ser significativa y la solución encontrada resulta cuestionable o puede decirse que no existe una solución bajo hipótesis de la teoría elástica multicapa (ARA Inc. y ERES C.D., 2004).

Por su parte, las aproximaciones **dinámicas** permiten considerar las características visco-elásticas del concreto asfáltico, la naturaleza dinámica inherente a la aplicación de la carga en pavimentos y, eventualmente, el espesor de la subrasante. En estas aproximaciones se busca determinar el módulo complejo de cada capa, el cual es función de la frecuencia angular, la viscoelasticidad de la capa asfáltica y el coeficiente de amortiguamiento de las capas granulares y subrasante. Los obstáculos que suelen presentar estas aproximaciones están relacionados con la complejidad y demoras computacionales, así como la ardua tarea para obtener todos los parámetros de entrada para el análisis.

Dentro de los estudios específicos que utilizan aproximaciones dinámicas de retrocálculo, se pueden mencionar: Stolle (1991); Ketcham (1993); Roesset *et al* (1994); Sebaaly *et al* (1986); Chang y Chang (1998); Kim y Ranjithan (1998); Matsui *et al* (1998); Al-Khoury *et al* (2000,

2001a, 2001b, 2002); Dong *et al* (2002); Loizos *et al* (2003); Chatti y Harichandran (2004); Loizos y Boukovalas (2005); Hu *et al* (2007), entre otros.

Más recientemente surgieron las aproximaciones **adaptativas** para retrocalcular los módulos de capa, las cuales aportan soluciones abiertas no deterministas, basadas en Redes Neuronales Artificiales principalmente. Estas técnicas no utilizan de manera directa un modelo de respuesta de deflexiones, sino que simulan un “mapa inverso” no lineal, con base en patrones de entrada y salida conocidos del comportamiento de la estructura. En los antecedentes de la investigación incluidos en el capítulo 1, se mencionan varios estudios puntuales donde se utilizaron estas aproximaciones para el retrocálculo de módulos de capa; en el capítulo 4 se profundizan los detalles de este tipo de modelaciones.

3.2.4 Indicadores estructurales derivados de pruebas de deflexión

Históricamente han surgido diversas propuestas para establecer indicadores de la capacidad estructural del pavimento a partir de la cuenca de deflexión, ya sea de manera directa, o calculados con métodos simplificados de naturaleza empírica, los cuales no tienen en cuenta de manera explícita las propiedades mecánicas de los materiales de las capas del pavimento. A continuación se describen algunos de los más comúnmente utilizados.

* **La deflexión máxima (D_{máx})** registrada bajo el eje de aplicación de la carga, describe cómo se comporta globalmente el pavimento ante una carga, pero no necesariamente refleja la resistencia individual de alguna de las capas. Así, sistemas débiles tendrán mayor D_{máx} que aquellos sistemas fuertes, bajo el mismo nivel de carga. Con base en casos de estudio, Chen y Scullion (2008) reportan que valores de D_{máx} superiores a 0.75 mm representan pavimento débiles que poseen estructuras delgadas, deterioro o capas granulares expuestas a humedad. En el ámbito local, Gómez *et al* (2007) y Zárate y Lucero (2009), reportan que valores superiores 0.7 mm son indicadores de una posible deficiencia estructural, atribuida principalmente a una subrasante débil.

En Costa Rica se efectuó un ejercicio interesante para clasificar la condición estructural de un pavimento en función de D_{máx} y del tránsito promedio diario – TPD, registrados en las vías nacionales de ese país, según se indica en la Tabla 3.2.

Tabla 3.2 Condición en función de D_{máx} y el TPD (Barrantes *et al*, 2008)

| TPD (veh/día) | D _{máx} (mm) | | | |
|---------------------------------|-----------------------|--------------------------|----------------------------------|------------------|
| | Bueno | Regular | Malo | Severo deterioro |
| 0 - 5000 | < 0.765 | 0.765 – 0.888 | 0.888 – 1.16 | > 1.16 |
| 5000 - 15000 | < 0.708 | 0.708 – 0.833 | 0.833 – 1.12 | > 1.12 |
| 15000 - 40000 | < 0.592 | 0.592 – 0.694 | 0.694 – 0.952 | > 0.952 |
| > 40000 | < 0.485 | 0.485 – 0.576 | 0.576 – 0.808 | > 0.808 |
| Intervención recomendada | Mantenimiento | Mantenimiento o refuerzo | Refuerzo si hay daño estructural | Reconstrucción |

Se aprecia que una $D_{máx}$ de 0.81 mm sobre una vía con alto tránsito representa un pavimento con severo deterioro, mientras que en una vía con bajo tránsito refleja una condición estructural regular; es decir, la tolerancia en la $D_{máx}$ para vías con altos volúmenes de tránsito es menor que en vías con tránsito bajo.

Como la resistencia y rigidez de las capas del pavimento está más asociada con la forma de la cuenca de deflexión que con la $D_{máx}$ (Mehta y Roque 2003; Shahin, 2005), resulta conveniente determinar otros indicadores que involucren información adicional del cuenco de deflexiones.

* **El área de la cuenca – A (Orozco, 2005)**, estimada como la sumatoria de áreas de los trapecios circunscritos en la mitad de la cuenca de deflexión, según se ilustra en la Figura 3.7.

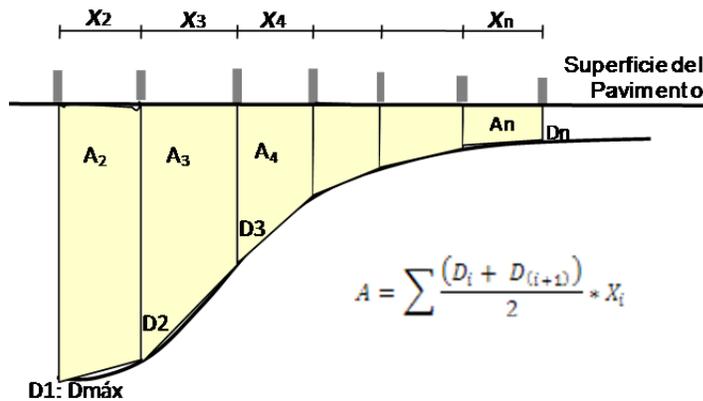


Figura 3.7 Área aproximada de la cuenca de deflexión

Donde:

n = número de sensores utilizados para medir la cuenca

D_i = Deflexión medida en el Sensor i (i varía de 1 a n)

D_n = Deflexión medida en el Sensor n

X_i = Distancia entre el Sensor i e $i-1$ (i varía de 2 a n)

Con base en los posibles valores de área, se han establecido intervalos para clasificar la condición y otorgar una calificación estructural según se muestra en la Tabla 3.3.

Tabla 3.3 Condición según el área de la cuenca de deflexión (Orozco 2005)

| A (mm ²) | Condición | Calificación estructural |
|----------------------|-----------|--------------------------|
| 0 a 100 | Excelente | 10 |
| 100 a 200 | Muy bueno | 9 |
| 200 a 400 | Bueno | 8 |
| 400 a 800 | Regular | 7 |
| 800 a 1600 | Malo | 6 |
| Mayor a 1600 | Pésimo | 5 |

* **El área normalizada de la cuenca - A_N .** Para su obtención, se divide la deflexión registrada en cada sensor por la deflexión máxima registrada bajo el punto de aplicación de la carga. Hoffman y Thompson (1982) propusieron una ecuación específica para el cálculo del área normalizada cuando se utilizan 4 sensores, separados a distancias constantes de 0.3 m, evaluando la cuenca hasta una distancia de 0.9m desde el eje de aplicación de carga:

$$A_{N0.9} = \frac{150 * (D_{m\acute{a}x} + 2 * D_{0.30} + 2 * D_{0.6} + D_{0.9})}{D_{m\acute{a}x}}$$

Siendo $D_{0.3}$, $D_{0.6}$ y $D_{0.9}$, las deflexiones registradas a distancias de 0.3, 0.6 y 0.9 m respectivamente del eje de aplicación de la carga. El $A_{N0.9}$ así determinada y la deflexión máxima, se han utilizado localmente como indicadores de la resistencia del pavimento y de la subrasante, según se muestra en la Figura 3.8 y en la Tabla 3.4.

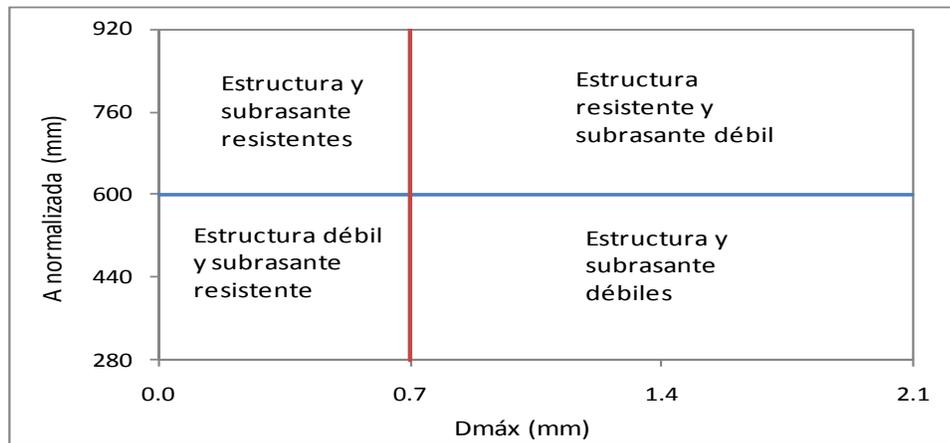


Figura 3.8 Resistencia de pavimentos según $D_{m\acute{a}x}$ y $A_{N0.9}$

Tabla 3.4 Características de resistencia en función del área normalizada y $D_{m\acute{a}x}$

| $A_{N0.9}$ (mm) | $D_{m\acute{a}x}$ (mm) | SUBRASANTE | PAVIMENTO |
|-----------------|------------------------|------------|------------|
| Baja (< 600) | Baja (< 0.7) | Resistente | Débil |
| | Alta (> 0.7) | Débil | |
| Alta (> 600) | Baja (< 0.7) | Resistente | Resistente |
| | Alta (> 0.7) | Débil | |

Fuente: Adaptada de Gómez et al (2007) y Zárate y Lucero (2009).

En la norma ASTM D5858, se propone una expresión más generalizada para la estimación del A_N en función del número de sensores y sus respectivas separaciones, para efectos de considerar aquellos casos donde se utilizan más de 4 sensores, según se indica a continuación:

$$A_N = \frac{X_2}{2} + \left[\frac{\sum_{i=2}^{n-1} D_i * (X_{i+1} + X_i)}{(2 * D_{m\acute{a}x})} \right] + \left[\frac{X_n * D_n}{(2 * D_{m\acute{a}x})} \right]$$

Donde:

n = número de sensores utilizados para medir la cuenca

X_2 = Distancia entre el Sensor 2 y 1

X_n = Distancia entre el Sensor n y $n-1$

X_{i+1} = Distancia entre el Sensor i e $i+1$

* **El índice Estructural – I_e .** Orozco (2005) propone determinar este índice adimensional mediante la relación indicada en la Figura 3.9. A menor valor de I_e , mejor condición de la estructura; en teoría esto se consigue con valores bajos de $D_{m\acute{a}x}$ y puntos de inflexión alejados del eje de carga, es decir en cuencas muy tendidas y poco profundas.

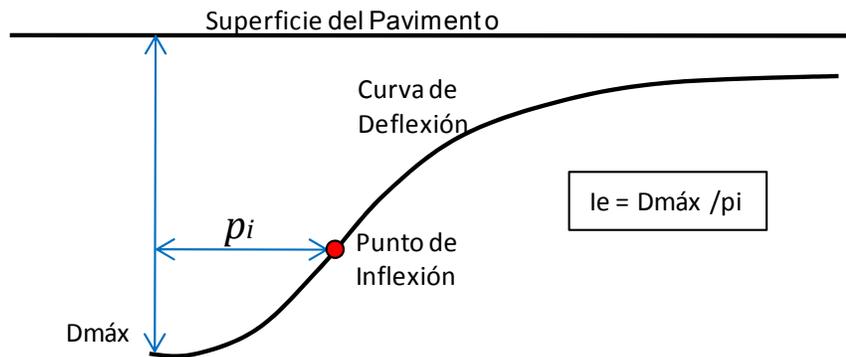


Figura 3.9 Determinación del índice estructural

Siendo p_i = Distancia horizontal desde el eje de carga al punto de inflexión que exhibe la curva de deflexiones (mm). La posición exacta del punto de inflexión, depende de las características estructurales de las capas que componen un pavimento específico. La evaluación de este índice para casos reales, dio lugar a proponer intervalos de valores para calificar la condición estructural del pavimento, desde excelente hasta pésima, asociados a las recomendaciones de intervención según se indica en la Tabla 3.5.

Tabla 3.5 Condición del pavimento según el Índice estructural (Orozco, 2005)

| Índice estructural (I_e) | Calificación Estructural (C_e) | | Solución a considerar - tránsito medio | |
|------------------------------|------------------------------------|-----------|--|--|
| 0 a 0.05 | 10 | Excelente | Tratamiento superficial | No intervenir si no hay deterioro; si grietas ligeras: micro-carpeta o rejilla de fibra de vidrio; si grietas severas a medias, fresado y reposición de carpeta. |
| 0.05 a 0.1 | 9 | Muy buena | | |
| 0.1 a 0.2 | 8 | Buena | Refuerzo | Sección invertida; fresado y carpeta si agrietamiento alto; reciclado (con emulsión o cemento asfáltico) + carpeta asfáltica polimerizada. |
| 0.2 a 0.3 | 7 | Regular | | |
| 0.3 a 0.4 | 6 | Mala | Recuperación <i>in situ</i> | Sección invertida; reciclado (con emulsión o cemento asfáltico) + carpeta asfáltica polimerizada; refuerzo superficial con micro-carpeta o rejilla de fibra de vidrio, si grietas ligeras. |
| > 0.4 | 5 | Pésima | | |

* **Factores de forma y otros indicadores.** Horark (1998) planteó dividir las cuencas de deflexión en tres distintas zonas según se ilustra en la Figura 3.10.

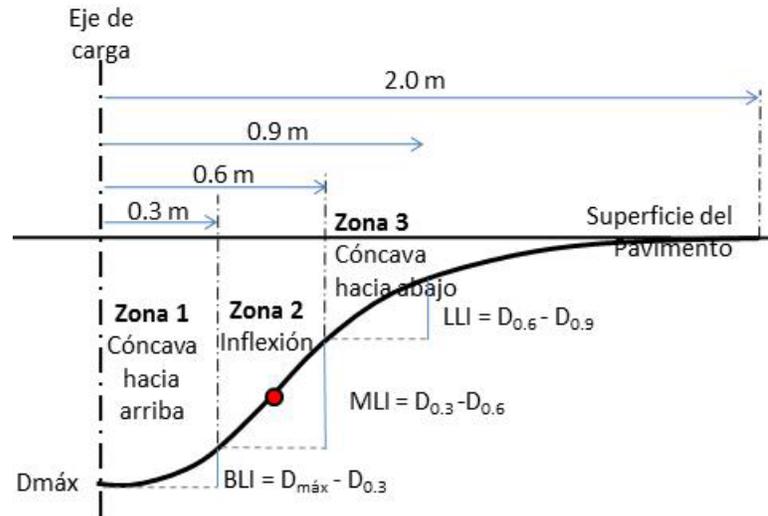


Figura 3.10 Zonas de curvatura en cuencas de deflexión

La zona 1 ubicada hasta 0.3 m aproximadamente del eje de carga, es cóncava hacia arriba y se asocia con la rigidez de las capas superiores de rodadura y base principalmente. La zona 2 ó zona de inflexión, está comprendida entre 0.3 m y 0.6 m del eje de carga, donde se presenta el cambio de curvatura en la cuenca y el punto de inflexión; se asocia principalmente con la rigidez de capa de subbase. La zona 3 presenta concavidad hacia abajo y se extiende hasta donde la deflexión sea cero; aunque esta zona comúnmente se limita entre 0.6 y 2.0 m del eje de carga, la extensión real depende del espesor de la estructura de pavimento y de la respuesta de las capas inferiores.

Con base en estas zonas, Horak y Emery (2006) propusieron algunos factores de forma mediante los cuales se intenta describir el comportamiento de un pavimento, pero considerando únicamente la porción de la cuenca de deflexiones comprendida hasta una distancia de 0.9 m del eje de carga, como se aprecia en la Figura 3.10.

En la Tabla 3.6 se incluyen los factores mencionados, y se definen otros índices adicionales encontrados en la literatura técnica, como el radio de curvatura de la cuenca RoC, el factor de forma F2, el módulo de rigidez dinámico MRD y la relación de deflexión RD.

Aunque el radio de curvatura y el índice de la base-BLI describen el comportamiento de las capas superficiales, se prefiere el uso del segundo parámetro cuando en las pruebas de deflexión se utilizan placas de carga rígidas de 0.15 m de radio; en esos casos, el RoC puede estar afectado por la cercanía del borde de la placa al sensor usado para su determinación.

Tabla 3.6 Factores de forma de las cuencas de deflexión y otros indicadores

| INDICADOR | DESCRIPCIÓN | EXPRESIÓN |
|---|--|---|
| Radio de curvatura, m | Evalúa la cuenca en la zona cercana al impacto de la carga -zona I* | $RoC = 0.04/(2(D_{m\acute{a}x}-D_{0.2}))$ |
| Índice de la base (antes índice de curvatura superficial) | Refleja la rigidez de las capas superficiales -zona I* | $BLI = D_{m\acute{a}x} - D_{0.3}$ BLI \approx 0: capas resistentes; BLI \approx $D_{m\acute{a}x}$: capas débiles |
| Índice de capas intermedias | Asociado con la rigidez de la subbase -zona II* | $MLI = D_{0.3} - D_{0.6}$ MLI > 0.15 mm: posible deficiencia (Xu, 2002) |
| Índice de capas inferiores | Indicador de la deformación por compresión sobre la subrasante -zona III* | $LLI = D_{0.6} - D_{0.9}$ |
| Factor de forma | Evalúa la rigidez relativa de las capas granulares. | $F2 = (D_{0.3}-D_{0.9})/ D_{0.3}$ Deseable: ≤ 0.5 |
| Módulo de rigidez dinámico | Evalúa la resistencia global de la estructura. Bajo el mismo nivel de carga, valores altos reflejan mayor resistencia. | $MRD = Q/D_{m\acute{a}x}$ Q = Impulso de carga. Deseable: ≥ 20 t/mm |
| Relación de deflexión | Capacidad de capas superiores respecto a la capacidad estructural total. | $RD = D_{0.3}/D_{m\acute{a}x}$ Rango deseable: 0.67 a 1.0 |

Fuente: Adaptada de Zárate (2011), Zárate y Lucero (2009), INVÍAS (2008), Horak y Emery (2006)*.

En la Tabla 3.7 se presentan una clasificación de la rigidez del pavimento en función de algunos indicadores mencionados, dependiendo del tipo de capa de base existente.

Tabla 3.7 Indicadores estructurales e intervalos de variación

| Base | Condición | $D_{m\acute{a}x}$ (mm) | RoC (m) | BLI (mm) | MLI (mm) | LLI (mm) |
|-------------|-----------|------------------------|-------------|-----------|------------|-------------|
| Granular | Adecuada | < 0.5 | > 0.1 | < 0.2 | < 0.1 | < 0.05 |
| | En riesgo | 0.5 – 0.75 | 0.05 – 0.1 | 0.2 – 0.4 | 0.1 – 0.2 | 0.05 – 0.1 |
| | Grave | > 0.75 | < 0.05 | > 0.4 | > 0.2 | > 0.1 |
| Con cemento | Adecuada | < 0.2 | > 0.15 | < 0.1 | < 0.05 | < 0.04 |
| | En riesgo | 0.2 - 0.4 | 0.08 – 0.15 | 0.1 – 0.3 | 0.05 – 0.1 | 0.04 – 0.08 |
| | Grave | > 0.4 | < 0.08 | > 0.3 | > 0.1 | > 0.08 |

Fuente: adaptada de Horak y Emery (2006)

3.3 Evaluación del deterioro estructural

Los insumos principales de esta evaluación son: la *medición de profundidad de roderas* en las huellas de circulación de los vehículos y *el inventario de daños estructurales* apreciables en la superficie del pavimento con su ubicación, magnitud, severidad y posibles causas.

Las *roderas* son causadas por la acumulación de deformaciones inelásticas o permanentes en las diferentes capas del pavimento con la repetición de cargas; la acción instantánea de una llanta sobre el pavimento genera una deflexión que se recupera parcialmente cuando la llanta deja de presionar quedando un remanente que se evidencia en las zonas de rodada de los vehículos

según se indica en la Figura 3.11. Estas deformaciones pueden agravarse y comprometer la servicialidad de la vía, aumentar los costos de operación y, en caso extremo, llevar a la ruptura.

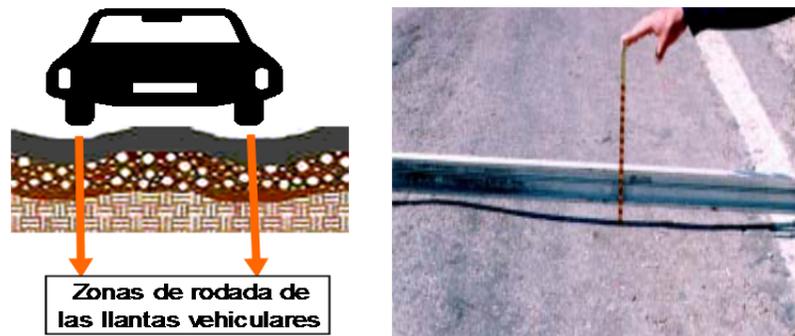


Figura 3.11 Deformaciones permanentes o roderas

En cuanto al *inventario de daños*, en la Figura 3.12 se presentan los tipos de deterioro estructural más frecuentes, incluyendo fenómenos de ruptura y deformación.



Figura 3.12 Algunos tipos de deterioro estructural

Para efectos de caracterizar un pavimento en función del deterioro, es posible definir indicadores de condición **individuales o integrados**. En la categoría **de indicadores individuales**,

cada tipo de deterioro constituye un tipo de falla independiente y es determinante en las acciones correctivas. Este es el caso aplicado en el proyecto NCHRP, donde se juzga la condición por cada deterioro según sea adecuada, marginal o inadecuada en función de la magnitud y/o severidad indicada en la Tabla 3.8.

Tabla 3.8 Valores sugeridos para juzgar la condición por deterioro

| TIPO DE DETERIORO | CONDICIÓN | | | INTERVENCIÓN PARA DAÑOS INADECUADOS |
|---|------------|----------|----------|--|
| | Inadecuada | Marginal | Adecuada | |
| Grietas por fatiga (% área) | > 20 | 5 a 20 | < 5 | Reparación total o parcial, fresado en frío, reciclado o sobrecarpeta |
| Grietas longitudinales (m/km) | > 200 | 50 a 200 | < 50 | Sello con o sin calafateo; reciclado; sobrecarpeta; repar. total o parcial |
| Grietas transversales (espaciamiento m) | < 30 | 30 a 60 | > 60 | Sello con o sin calafateo; reciclado; sobrecarpeta; repar. total o parcial |
| Grietas de reflexión (ancho mm) | > 12 | 6 a 12 | < 6 | Reparación total o parcial o sellado con o sin calafateo |
| Roderas (mm) | > 10 | 6 a 10 | < 6 | Renivelación; reciclado en frío o en caliente; micro o sobre-carpeta |
| Ondulaciones (% área) | > 10 | 1 a 10 | < 1 | Renivelación o sobrecarpeta |
| Baches abiertos o reparados (% área) | > 15 | 8 a 15 | < 8 | Bacheo superficial o profundo. Prevención: sello de grietas |

Adaptada de ARA, Inc. y ERES Consultants Division NCHRP-TRB-NRC-2004.

Bajo los criterios anteriores, cualquier daño “inadecuado” requiere rehabilitación profunda o de gran escala; si existen daños “marginales”, el pavimento requiere acciones correctivas prontas para evitar alcanzar niveles inadecuados.

Existen otros criterios internacionales reconocidos en nuestro medio, que basan las recomendaciones según la intensidad de cada deterioro. En la Tabla 3.9 se presentan las alternativas recomendadas para los tipos de deterioro de interés para esta investigación.

Tabla 3.9 Soluciones recomendadas por agencias internacionales según deterioro

| DAÑO | ALTERNATIVAS (1) | ALTERNATIVAS (2) |
|--------------------|--|--|
| Grietas por fatiga | Ligeras: sello. Medias a severas: bacheo superficial o profundo; sobrecarpeta; reconstrucción. | Ligeras: lechada superficial en áreas afectadas o en todo el tramo. Medias a severas: sustitución de carpeta y eventualmente de la base. |
| Bache ab. | Bacheo parcial o profundo. | Bacheo aislado; sobrecarpeta en área afectada; recuperación de rodadura y parte de la base. |
| Bache rep. | Sustitución si está deteriorado | |
| Roderas | Renivelación; sobrecarpeta con o sin fresado; bacheo superficial o profundo. | Renivelación local o continua; fresado y sustitución de rodadura en la banda afectada |

(1) U.S. Army Corps of Engineers, 2001.

(2) Consejo de directores de carreteras de Iberoamérica, 2002

En la evaluación de **indicadores integrados**, los diferentes tipos de deterioro se combinan para definir índices que representen la condición del pavimento y orienten la elección de alternativas de conservación o rehabilitación; a continuación se describen algunos ejemplos de esta categoría de indicadores.

- **El índice de condición del pavimento – PCI** (por sus siglas en inglés), planteado por el Cuerpo de Ingenieros de los Estados Unidos; se puede determinar según la norma ASTM D6433-03. El PCI considera cada tipo de daño tanto estructural como funcional, su magnitud y severidad, para clasificar la integridad global del pavimento según se indica en la Tabla 3.10.

Tabla 3.10 Índice de Condición del Pavimento – PCI

| PCI | CLASIFICACIÓN |
|----------|---------------|
| 100 – 85 | Excelente |
| 85 – 70 | Muy Bueno |
| 70 – 55 | Bueno |
| 55 – 40 | Regular |
| 40 – 25 | Malo |
| 25 – 10 | Muy Malo |
| 10 – 0 | Pésimo |

Fuente: Ladd M. y Grau R. U.S. Army Corps of Engineers (2001).

- **El índice de degradación superficial-Is** del método VIZIR, propuesto en el año 1991 por el Laboratorio Central de Puentes y Carreteras - LCPC de Francia. Integra la magnitud y la gravedad de los daños tipo fisuras y deformaciones. El valor de Is puede aumentar con la presencia de baches abiertos o reparados. En la Tabla 3.11 se presentan las condiciones que puede presentar el pavimento en función de Is, y las intervenciones globales sugeridas.

Tabla 3.11 Índice de degradación superficial – Is

| Is | CONDICIÓN | DESCRIPCIÓN |
|----------|------------|--|
| 1 y 2 | Buena | Pocas fisuras y deformaciones (0% a 10% del área). Requiere eventual mantenimiento rutinario. |
| 3 y 4 | Regular | Fisuras en 10% a 50% del área y deformaciones en 0% a 10% del área. O pavimentos con fisuras en 0% a 10% del área y deformaciones en 10% a 50% del área. Requiere rehabilitación de mediana intensidad |
| 5, 6 y 7 | Deficiente | Abundantes fisuras, deformaciones (> 50% del área). Requiere trabajos importantes de rehabilitación. |

Fuente: LCPC método VIZIR Francia, 1991.

En el ámbito local es común aplicar criterios basados en la práctica y la experiencia de expertos. En el ejemplo de la Tabla 3.12, se clasifica la condición del pavimento según la magnitud y severidad de los daños y asociado a ello, se formulan recomendaciones de intervención.

Tabla 3.12 Criterios locales para evaluar la condición por deterioro

| NIVEL | CONDICIÓN | DESCRIPCIÓN |
|-------|-----------|---|
| 0 | Excelente | Área con grietas ligeras y/o deterioro <5%; no requiere conservación |
| 1 | Muy buena | 5 a 10% del área con grietas ligeras a moderadas y/o con roderas ligeras; requiere conservación local preventiva. |
| 2 | Buena | 10 a 20% del área con grietas, roderas y daño ligero a moderado; ó <5% del área con grietas, roderas y defectos severos; conservación menor preventiva |
| 3 | Regular | 20 a 30% del área con grietas, roderas y daños ligeros a moderados; de 5 a 10% del área con grietas, roderas y daños severos; requiere conservación local de rutina |
| 4 | | 30 a 40% del área con grietas, roderas y daños ligeros a moderados; ó 10 a 15% del área con grietas, roderas y daños severos; requiere conservación local menor de rutina y conservación general preventiva, fresado y repavimentación opcional |
| 5 | | 40 a 45% del área con grietas, roderas y daños ligeros a moderados; ó 15 a 25% del área con grietas, roderas y daños severos; requiere conservación local menor, conservación general preventiva y conservación mayor en el área |
| 6 | Mala | 45 a 55% del área con grietas, roderas y daños ligeros a moderados; ó 25 a 55% del área con grietas, roderas y daños severos; conservación menor y mayor en el área |
| 7 | | 55 a 60% del área con grietas, roderas y daños ligeros a severos; requiere conservación mayor en el área |
| 8 | Muy mala | 60 a 70% del área con grietas, roderas y daños ligeros a severos; requiere conservación mayor en el área |
| 9 | Pésima | Más de 70% del área con grietas y/o roderas; hasta 100% del área con daños ligeros a severos; requiere conservación mayor y/o reconstrucción total del área |

Fuente: Orozco, Raúl V. (2005)

3.4 Definición de sectores homogéneos de comportamiento

Como producto de las campañas de auscultación para la evaluación de carreteras, se generan listados con información muy detallada, punto a punto del corredor. Mediante el procesamiento de la información recopilada en campo, se estiman nuevas variables y parámetros, los cuales entran a formar parte de una base de datos global del corredor. La magnitud de las bases de datos depende de la cantidad de parámetros medidos, la longitud del corredor y la densidad de las mediciones.

Una evaluación punto a punto, permite tener una caracterización estructural completa y detallada del corredor, pero también resulta bastante dispendiosa y poco práctica para el analista, por el tiempo que consume. Usualmente, resulta conveniente dividir la longitud total de un corredor vial en tramos con respuestas o propiedades del pavimento similares para simplificar la evaluación.

Mediante el análisis de los diferentes componentes de la evaluación, es posible identificar variaciones significativas a lo largo de un corredor, desde el punto de vista de respuesta mecánica y de desempeño. Para ello, resulta útil graficar perfiles longitudinales de la vía analizada con las propiedades de las capas del pavimento, la magnitud y severidad del deterioro

estructural, entre otros; en función de las variaciones observadas se pueden definir sectores de comportamiento homogéneo.

Aunque esta tarea suele realizarse visualmente a criterio del analista, existen procedimientos que ayudan a definir las fronteras. En la guía AASHTO (1993) se describe el método de diferencias acumuladas para definir sectores en función de cambios significativos con respecto a algún parámetro de comportamiento. El método se basa en la definición de la variable Z_c , de acuerdo con la siguiente expresión, considerando los conceptos mostrados en la Figura 3.13:

$$Z_c = Aaccum_x - (At/Lt) * X$$

Donde:

$Aaccum_x$ = Área bajo la curva de respuesta de un parámetro en particular, a cualquier distancia X desde el punto inicial del tramo.

At/Lt = Área promedio de la curva de respuesta en todo el corredor o área por unidad de longitud.

Al graficar el perfil longitudinal de la variable Z_c , los límites entre sectores quedan definidos como aquellos sitios en los cuales la pendiente de la gráfica cambia de signo, tal como se ilustra en la Figura 3.14.

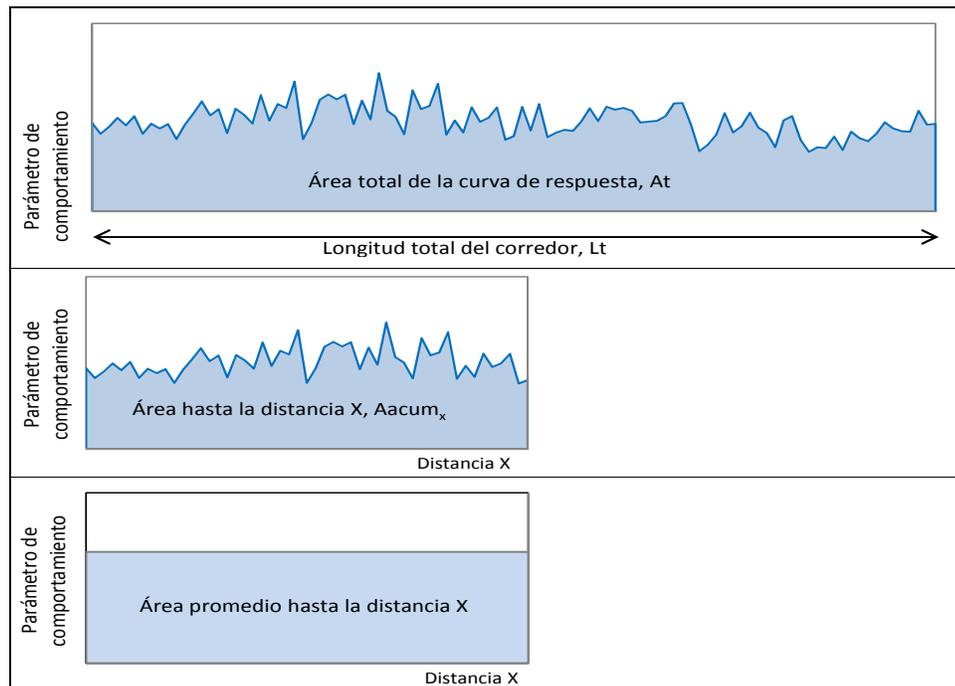
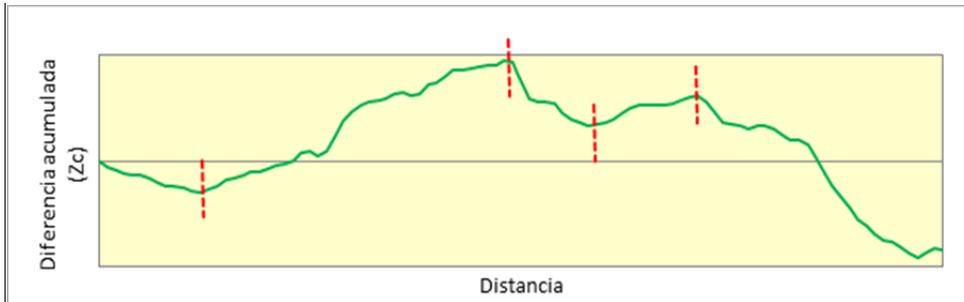


Figura 3.13 Conceptos que definen las diferencias acumuladas de áreas

Figura 3.14 Definición de sectores en función de Z_c

El método puede aplicarse en función de cada parámetro o indicador de respuesta de manera individual, pero es recomendable utilizarlo con las variables más significativas del comportamiento, y combinarlo con la técnica visual, buscando obtener sectores cuya longitud permita diseñar y construir acciones de rehabilitación de manera práctica.

Regularmente se definen fronteras iniciales según los sistemas de pavimento presentes en un corredor, evidenciados en cambios de espesores de capa o cambios en los materiales; tales fronteras se van refinando por el método de diferencias acumuladas en función de las deflexiones u otros parámetros de interés particular, hasta obtener una sectorización razonable por comportamiento mecánico del corredor. Cada uno de los sectores así establecidos, se caracteriza mediante parámetros y propiedades promedio de los valores registrados o estimados en cada tramo.

Con el análisis particular de cada sector, se establece la condición estructural y se identifican los problemas con su nivel de gravedad. Es posible encontrar dentro de un sector homogéneo, zonas muy localizadas con deterioro abundante o severo o valores atípicos de algún parámetro; tales casos ameritan análisis específicos para identificar eventuales causas.

3.5 Modelos de deterioro

Para contar con elementos que apoyen la toma de decisiones en cuanto al momento en que se deben efectuar las actividades de mantenimiento y conservación, es necesario pronosticar las condiciones que exhibirá el pavimento hacia el futuro durante un cierto tiempo de análisis.

No existe un modelo universal que pueda predecir la evolución del deterioro ni la vida remanente de los pavimentos, pues el éxito de las predicciones de los modelos existentes depende fundamentalmente del tipo de estructura a analizar (Abdallah *et al*, 2000).

Generalmente se han asumido los criterios de falla por fatiga y por deformación los cuales se relacionan directamente con grietas por fatiga y profundidad de roderas, cuya progresión se ha estimado tradicionalmente mediante la Ley de Miner, dada por la siguiente relación:

$$D = \sum_{i=1}^T \frac{n_i}{N_i}$$

Donde:

- D Daño por fatiga o por deformación
- T Número total de periodos considerados
- n_i Tránsito esperado para el periodo i
- N_i Tránsito permitido bajo las condiciones prevalecientes en el periodo i .

La Ley de Miner indica que el daño progresa linealmente en función del tránsito y podría utilizarse de manera aproximada para estimar la vida remanente según criterios de fatiga. En ese caso, N_i se puede determinar en pruebas de laboratorio con carga repetida para establecer la ley de fatiga de la capa asfáltica, es decir el número de ciclos de carga para alcanzar la falla por fatiga y la deformación crítica a tensión. También se puede estimar mediante las ecuaciones propuestas por el Instituto Norteamericano del Asfalto, Shell, entre otras, pero igualmente, hay que conocer los módulos de capa y las deformaciones críticas.

En cuanto a la falla por deformación permanente, la Ley de Miner no resulta confiable, pues la profundidad de roderas no progresa de manera lineal con el tránsito (ARA, Inc. & ERES Consultants Division, 2004).

Las tendencias recientes se han centrado en desarrollar modelos cada vez más complejos que reflejen la dependencia de múltiples variables, algunas de las cuales no se pueden determinar rápidamente o no siempre se encuentran disponibles para el analista.

Existen en la literatura técnica, diferentes metodologías y modelos de deterioro, que pueden tomarse como punto de partida para establecer la vida remanente del pavimento y para identificar tendencias típicas en los comportamientos futuros. Desafortunadamente no se cuenta con desarrollos propios para el medio mexicano debidamente calibrados y validados para las condiciones locales.

Los modelos de deterioro desarrollados en el estudio de Paterson (1987), constituyen una aproximación hacia análisis mecánico-empíricos de pavimentos; estos modelos son reconocidos en el medio, poseen amplio sustento teórico y experimental y constituyen la base para el sistema de administración de carreteras HDM-4 (Association Mondiale de la Route – World Bank, 2000).

El estudio de Paterson provee modelos para predecir el deterioro por agrietamiento, roderas y baches. Este último no se aplica en este trabajo, considerando el alto impacto que este tipo de daños tiene tanto en las condiciones funcionales como estructurales del pavimento; se plantea que cualquier bache existente debe repararse inmediatamente, controlando su reaparición mediante monitoreo y mantenimiento periódico.

Para esta investigación sólo se consideran aquellos modelos que permitan modelar la progresión de daños existentes para un caso de estudio seleccionado. No se evalúa por ejemplo, el tiempo de iniciación del agrietamiento en tramos no deteriorados, pues se encontró gran incertidumbre con algunas de las variables de entrada al modelo para el caso de estudio.

A continuación se exponen los modelos desarrollados para predecir la evolución del *agrietamiento por fatiga y de deformaciones permanentes*.

Modelo de agrietamiento

La progresión del agrietamiento por fatiga, se determina mediante el modelo de grietas estructurales, el cual se basa en un modelo incremental que predice el porcentaje de área agrietada con el tiempo; para evaluaciones anuales la expresión de cálculo está dada por:

$$\Delta ACA = K_{cpa} \left[\frac{1 - 0.12 * CRT}{CDS} \right] Z_A \left[(Z_A a_0 a_1 + SCA^{a_1})^{\frac{1}{a_1}} - SCA \right]$$

$$ACA = ACAa + \Delta ACA$$

Siendo:

ACAa y ACA % de área agrietada al comienzo y al final de un año determinado

ΔACA incremento del agrietamiento durante el año

K_{cpa} Factor de calibración. (Valor sugerido por defecto en HDM4: 1)

CRT Retardo en el agrietamiento por efecto de mantenimiento (3 años, máximo)

CDS Calidad de la construcción de capas asfálticas (1 para contenido óptimo de asfalto)

SCA y Z_A : Si $ACAa \leq 50\%$: $SCA = ACAa$ y $Z_A = 1$. En caso contrario: $SCA = 100 - ACAa$ y $Z_A = -1$

a_0 y a_1 Coeficientes de agrietamiento que dependen del tipo de pavimento

Modelo de deformación permanente

Para estimar la evolución de la profundidad de roderas para vías que tienen varios años de servicio, existen modelos para evaluar las componentes de *deformación plástica* atribuida a la capa asfáltica y de *deformación estructural* asociada con las capas granulares e inferiores.

La expresión propuesta para estimar la *deformación plástica*, está dada por:

$$\Delta RDPD = K_{rpd} \{ CDS^3 a_0 Y E 4 S h^{a_1} H S^{a_2} \}$$

Siendo:

K_{rpd} Factor de calibración. (Valor sugerido por defecto en HDM4: 1)

Sh Velocidad de los vehículos pesados (km/h)

HS Espesor de la capa asfáltica

a_0 , a_1 y a_2 Valores sugeridos de 2.46, -0.78 y 0.71, para rodadura asfáltica
 YE4 Número anual de ejes equivalentes en millones/carril. Para carreteras con 2 carriles:

$$YE4 = \sum T_k * ESALF_k / (2 * 10^6)$$

Donde:

T_k Volumen de tránsito anual por tipo de vehículo k (bus, camión de dos ejes C2, ...)
 $ESALF_k$ Factor de equivalencia de carga por eje para el vehículo tipo k, teniendo en cuenta el efecto del daño causado por cada configuración de ejes.

La metodología formal para determinar el $ESALF_k$, se deriva del "AASHO Road Test", aunque también puede estimarse mediante metodologías propuestas por SHELL, el Instituto Norteamericano del Asfalto, entre otros. En la actualidad es común utilizar una aproximación muy simple para efectos meramente prácticos, a partir de la expresión sugerida por Watanatada *et al.* (1987); para pavimentos de concreto asfáltico, la expresión se conoce en algunos medios como método de la cuarta potencia o método simplificado de la AASHTO.

$$ESALF_k = \sum (AXL_j / SAXL_j)^4$$

Siendo:

AXL_j = Carga promedio por eje j (simple, tándem, trídem),

$SAXL_j$ = Carga estándar de referencia por cada eje j.

En la Tabla 3.13 se presentan los valores para estos dos parámetros que podrían aplicarse al medio mexicano, y su relación a la cuarta potencia, en función del tipo de eje.

Tabla 3.13 Valores de carga para cada grupo de ejes.

| EJE | AXL* (ton) | SAXL** (ton) | (AXL/SAXL) ⁴ |
|------------------------|---------------|-----------------|-------------------------|
| Simple llanta sencilla | 6.5 | 6.6 | 0.9 |
| Simple llanta doble | 10 | 8.2 | 2.2 |
| Simple motriz | 11 | 8.2 | 3.2 |
| Tándem | 17 | 15 | 1.6 |
| Tándem motriz | 18 | 15 | 2.0 |
| Trídem | 23.5 | 23 | 1.1 |

* SCT (2008)

**AASHTO (1993)

Con base en las configuraciones de cada tipo de vehículo, se proponen los valores mostrados en la Tabla 3.14 para las categorías de vehículos reportadas por la SCT en las carreteras nacionales. Con estos valores es posible calcular el número de ejes equivalentes de carga por carril en determinada carretera, para diferentes años de pronóstico.

Tabla 3.14 ESALF por tipo de vehículo

| TIPO DE VEHÍCULO | ESALF |
|--------------------------|-------|
| Bus | 2.5 |
| Camión de dos ejes, C2 | 3.1 |
| Camión de tras ejes, C3 | 2.5 |
| Camión de 5 ejes, T3S2 | 4.5 |
| Camión de 6 ejes, T3S3 | 4.0 |
| Camión de 9 ejes, T3S2R4 | 7.7 |

El modelo de *deformación estructural* por su parte, permite estimar los incrementos en cada año de análisis dependiendo de la presencia de agrietamiento, según las siguientes expresiones:

- Sin agrietamiento

$$\Delta RDST_{uc} = K_{rst} \{a_0 SNP^{a_1} YE4^{a_2} COMP^{a_3}\}$$

$$SNP = 3.2 * Dmáx^{-0.63}$$

- Con agrietamiento

$$\Delta RDST_{crk} = K_{rst} \{a_0 SNP^{a_1} YE4^{a_2} MMP^{a_3} ACA_a^{a_4}\}$$

$$SNP = 3.2 * Dmáx^{-0.63} - 0.00007.58 * HS * \Delta ACA$$

SNP Número estructural ajustado
 Krst Factor de calibración. (Valor sugerido por defecto en HDM4: 1)
 COMP Compactación relativa de base, subbase e inferiores
 MMP Precipitación media mensual
 a₀, a₁, a₂, a₃ y a₄ Coeficientes sugeridos en la Tabla 3.15

Tabla 3.15 Coeficientes del modelo de deformación estructural

| Modelo | a ₀ | a ₁ | a ₂ | a ₃ | a ₄ |
|-------------------|----------------|----------------|----------------|----------------|----------------|
| Sin agrietamiento | 44950 | -1.14 | 0.11 | -2.3 | - |
| Con agrietamiento | 0.0000248 | -0.84 | 0.14 | 1.07 | 1.11 |

La profundidad total media de roderas para cualquier año se define como:

$$RDM_b = RDM_a + \Delta RDSTb + \Delta RDPDb$$

Donde:

RDM_b Profundidad media de roderas en ambas huellas al final del año
 RDM_a Profundidad media de roderas en ambas huellas al inicio del año
 ΔRDSTb Incremento de deformación estructural al final del año
 ΔRDPDb Incremento de deformación plástica al final del año.

4 HERRAMIENTAS DE LA INTELIGENCIA ARTIFICIAL

La Inteligencia Artificial-IA, se asocia con el desarrollo de máquinas y programas de cómputo “inteligentes” (McCarthy, 1956), para modelar sistemas variables complejos, con la posibilidad de involucrar cada vez más el razonamiento y pensamiento humano en la programación de algoritmos computacionales. Mediante la aplicación de la IA es posible almacenar grandes volúmenes de información, solucionar problemas en diversas áreas, con la capacidad de adaptarse a nuevas condiciones y adquirir nuevo conocimiento desde la experiencia.

En este capítulo se exponen los elementos básicos sobre las técnicas consideradas en esta investigación como métodos no convencionales de modelación: Redes Neuronales Artificiales - RNAs, Lógica Difusa - LD y sistemas combinados RNA-LD; en el Anexo A se presentan algunos aspectos del desarrollo histórico de estas herramientas.

Un área específica de aplicación de estas herramientas, es la relacionada con los sistemas de identificación, cuyo objetivo es modelar comportamientos basados en datos de entrada-salida, determinando primero la **estructura** del sistema que representa un fenómeno o problema y luego los **parámetros** del modelo asociados con los datos numéricos observados en el sistema (Sugeno y Yasukaua, 1993).

4.1 Redes Neuronales Artificiales - RNAs

Las RNAs han sido consideradas como herramientas computacionales particularmente adecuadas para la solución de problemas tanto de clasificación como de regresión en análisis multivariados. En el primer caso, tienen la habilidad de reconocer patrones y extraer características esenciales a partir de un conjunto de datos de entrada con información relevante sobre un sistema o fenómeno que se quiere analizar.

Para problemas de regresión, las RNAs son útiles en la búsqueda de relaciones complejas entre variables o patrones de entrada y de salida; pueden aprender con base en la experiencia y el conocimiento previo para estimar o pronosticar comportamientos de manera aproximada. Obviamente, debe existir una relación entre las entradas y las salidas o patrones reconocibles

en un conjunto de datos, pues de lo contrario “no habría nada que aprender”; por ello, no son útiles en procesos que implican el azar. Al incorporar nueva información, son capaces de generalizar hacia nuevos casos y asimilarlos para mejorar su capacidad de predicción, mediante su habilidad de aprendizaje continuo o adaptabilidad, denominada “plasticidad”.

Estas técnicas involucran la imprecisión e incertidumbre propia del análisis de fenómenos o sistemas naturales, cuya complejidad dificulta la construcción de modelos para analizar su comportamiento. Por ello, resultan útiles en procesos que no pueden representarse fácilmente y de manera explícita en términos matemáticos o estadísticos, o cuando éstos no son suficientes para representar de manera realista el comportamiento; además, permiten resolver problemas donde intervienen múltiples variables.

Los sistemas neuronales artificiales toman como referente las redes neuronales biológicas y en especial, la complejidad de la estructura y la eficiencia del cerebro humano para procesar información y tomar decisiones, donde la inteligencia es producto de la alta conectividad existente entre la gran cantidad de neuronas (Haykin, 1999). De manera análoga, las RNAs están conformadas por unidades de procesamiento o *neuronas* interconectadas las cuales reciben, procesan y transmiten señales o información hacia las otras con las cuales tienen conexión; estas señales pueden ser de tipo inhibitorio o activador.

En la Figura 4.1 se muestra un esquema con el funcionamiento general de una neurona N_i , la cual recibe un vector de entrada conformado por las señales X_j , para generar una señal de salida Y_i en función de las entradas. Cada una de las conexiones de la neurona con sus entradas tiene asociado un valor llamado peso W_{ij} , del cual dependerá la intensidad de la señal transmitida; el conjunto de valores de W_{ij} , conforman el vector de pesos.

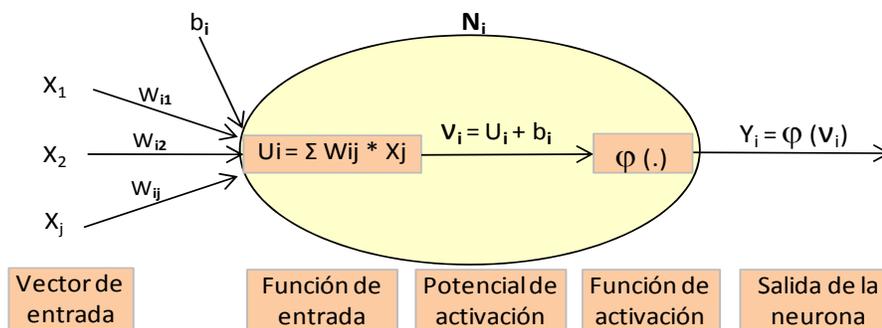


Figura 4.1 Esquema funcional de una neurona artificial

En principio, cada vector de entrada se combina o pondera de algún modo con el vector de pesos, aplicando una función de entrada U_i ; el caso ilustrado en la Figura 4.1 corresponde a la función producto punto. El resultado de esta combinación, se afecta por una entrada externa denominada bias b_i o sesgo, introducida para aumentar un grado de libertad al modelo neuronal, con lo cual se obtiene el potencial de activación o campo local inducido V_i . A

este potencial se le aplica finalmente una función de activación o de transferencia $\phi(\cdot)$, con el fin de limitar la magnitud de la señal de salida de la neurona Y_i dentro de un rango finito.

4.1.1 Estructura de las RNAs

Las redes más utilizadas son las multicapa y las recurrentes; las primeras, son sistemas de varios niveles en paralelo, constituidas por una capa de entrada que recibe las variables externas, una capa de salida y capas intermedias u ocultas que le aportan dimensionalidad al problema al introducir conjuntos adicionales de conexiones (Churchland and Sejnowski, 1992). El aprendizaje se propaga hacia adelante (de las entradas hacia las salidas) y no se permite la comunicación entre neuronas de una misma capa. Los arreglos o arquitecturas más complejas se asocian comúnmente con problemas altamente no lineales y multivariados y generalmente requieren mayor tiempo de aprendizaje y por tanto menor velocidad (Abdallah, *et al*, 2000).

Por su parte, las RNAs recurrentes poseen bucles de retroalimentación en alguna parte de su estructura, de manera que una neurona puede quedar alimentada y retroalimentada por las señales de salida de cualquier otra neurona de la red, lo cual se ha encontrado bastante útil en problemas que involucran sistemas dinámicos no lineales o dependientes del estado.

En la Figura 4.2 se presenta un modelo esquemático de una RNA multicapa de *propagación normal* hacia adelante para resolver un problema de regresión; aquí, las señales de salida de las neuronas de la capa de entrada, constituyen las señales de entrada a las neuronas de la capa oculta y así sucesivamente con las demás capas, siguiendo un proceso de activación similar al ya descrito en el modelo de neurona simple para la propagación de información a través de la red.

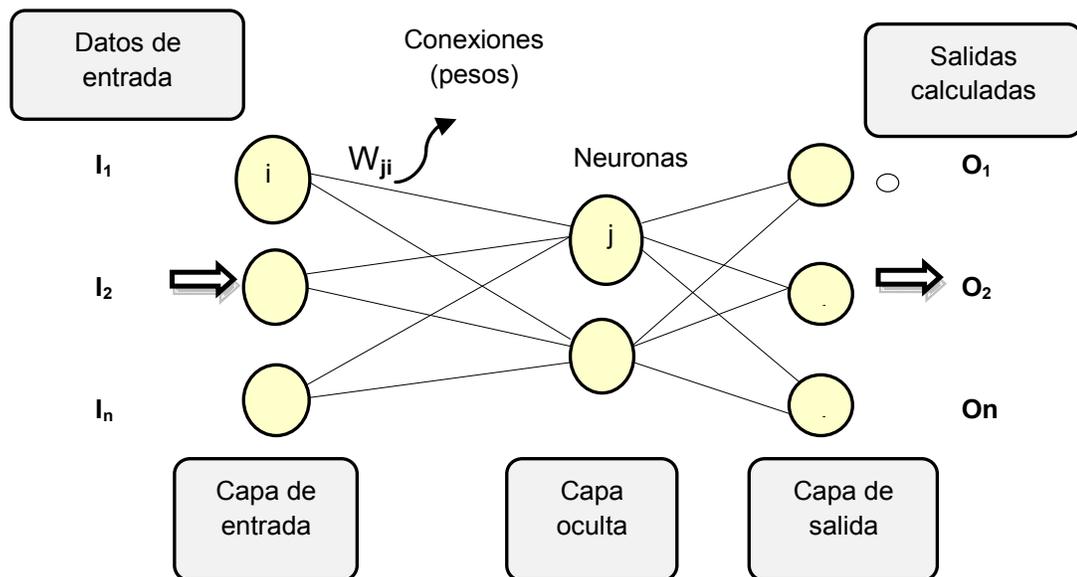


Figura 4.2 Configuración básica de un modelo de red neuronal

Como resultado, las señales de salida de las neuronas de la última capa involucran la repuesta global de la toda red ante las entradas suministradas a la primera capa. Si cada una de las capas de la red recibe señales externas y señales de todas las capas precedentes, se dice que es una red de *propagación total* hacia adelante.

El desempeño de las RNAs dependerá fundamentalmente de la calidad y cantidad de datos presentados a la red, del modo en que las neuronas están interconectadas (arquitectura o arreglo de la red), de que tan fuertes sean esas conexiones (valor de los pesos) y de la manera que se realiza el aprendizaje (regla o algoritmo de aprendizaje). De este modo, la estructura y estado de activación de la red neuronal representa el conocimiento, definido como la información que se adquiere o almacena para interpretar, predecir y responder posteriormente ante estímulos externos.

En la modelación con RNAs una buena solución a un problema se logra con una buena representación del mismo (Woods, 1986), de modo que el diseño de la red en sí, se convierte en uno de los objetivos principales.

4.1.2 Diseño de un modelo neuronal

En el proceso de diseño se deben definir los siguientes elementos: la arquitectura de la red, las funciones de entrada, de transferencia, de error, el tipo de pre-procesamiento de los datos de entrada y el algoritmo de aprendizaje, entre otros. Todos estos elementos dependen del problema a abordar y de la base de datos disponible; para su definición se requiere un arduo trabajo, regularmente mediante ensayo y error.

a) **La Arquitectura de la red.** Define la topología o configuración general de las conexiones entre neuronas, es decir la cadena de comunicación entre los nodos que conforman una red; en algunos casos la arquitectura seleccionada condiciona el número de capas ocultas en la red. Paralelamente con la arquitectura, se debe establecer el número de neuronas y conexiones que se requieran para construir el modelo que mejor refleje el comportamiento del sistema que se pretende analizar.

La notación para una RNA cualquiera sería $I-H_1-H_i-\dots-O$, siendo I el número de nodos en la capa de entrada, H_i el número de nodos en cada capa oculta y O el número de neuronas en la capa de salida; si sólo existe una capa oculta, la notación se reduce a $I-H-O$. Cuando se requiere alto grado de precisión o manejo de datos confusos (ruido) conviene disponer un gran número de neuronas asociados al fenómeno que se quiere representar.

b) **El algoritmo o regla de aprendizaje.** Es responsable del proceso adaptativo, es decir del ajuste iterativo de los pesos en las conexiones entre neuronas; condiciona la velocidad del proceso y los niveles de precisión. Se pueden manejar diferentes reglas por cada capa de la red. El aprendizaje puede ser de tres tipos:

- a. *Supervisado*, cuando se conocen las salidas para las entradas especificadas; en este caso se aprende “con base en el ejemplo” relacionando patrones de entrada-salida con el comportamiento del sistema, sin hacer suposiciones previas sobre dichas relaciones. Este tipo de aprendizaje puede aplicarse en problemas de regresión.
- b. *Reforzado* o graduado cuando no se conocen las salidas, pero se tienen algún indicio sobre ellas; puede usarse para tareas supervisadas pero suele requerir más tiempo.
- c. *No-supervisado* para problemas de clasificación donde no se conocen las salidas; la red recibe las entradas y encuentra patrones significativos para efectos de agrupamiento o para preprocesamiento de datos. (LDC Inc., 1996).

En la Tabla 4.1 se presentan algunos de los algoritmos de aprendizaje que se pueden seleccionar en función de la arquitectura de la red y en la 0 se describen detalles aquéllos de mayor interés para este estudio.

Tabla 4.1 Algoritmos de aprendizaje y arquitecturas usuales en RNAs

| TIPO DE APRENDIZAJE | ALGORITMO DE APRENDIZAJE | ARQUITECTURA | | | | | | | |
|------------------------|--------------------------------------|--|---|---------|------------------|-------------------|------------------|-------------------|-----------------------|
| | | Multicapa de propagación normal hacia adelante | Multicapa de propagación total hacia adelante | Cascada | Elman Recurrente | Jordan Recurrente | Total recurrente | Recurrente previa | Recurrente en Cascada |
| Supervisado | Retro-propagación | X | X | X | X | X | | | |
| | Propagación rápida | X | X | X | X | X | | | |
| | Retro-propagación Jacob mejorada | X | X | X | X | X | | | |
| | Cuantif. vector de aprendizaje - LVQ | X | X | | | | | | |
| | Correlación en cascada | X | X | X | | | | | |
| | Gradientes conjugados | X | X | X | X | X | | | |
| | Levenberg Marquardt | X | X | X | | | | | |
| | Red neuronal probabilística | X | X | | | | | | |
| | Red neuronal de regresión general | X | X | | | | | | |
| Diferencias temporales | X | X | X | | | | | | |
| Reforzado | Enfriamiento simulado | X | X | X | X | X | X | X | X |
| | Optimizac. aleatoria de Solis & Wets | X | X | X | X | X | X | X | X |
| | Enfriamiento simulado simple | X | X | X | X | X | X | X | X |
| | Método de Powell | X | X | X | X | X | X | X | X |
| | Retro-propagación recurrente | X | X | | | | X | | |
| No-supervisado | Kohonen WTA | X | X | | | | | | |

Tabla 4.2 Características de algunos algoritmos de aprendizaje

| TIPO | ALGORITMO | CARACTERÍSTICAS |
|----------------|---------------------------|--|
| Supervisado | Retro-propagación | Es un algoritmo de gradiente descendente con una sólida capacidad para alcanzar la generalización, aunque tiene la desventaja de que la red puede quedar atrapada en un mínimo local. La magnitud del incremento en los pesos se fija antes del entrenamiento y permanece constante durante el proceso de aprendizaje. |
| | Propagación rápida | Minimiza el tiempo de aprendizaje evaluando la tendencia del ajuste de los pesos con el tiempo y heurísticamente detecta y optimiza los incrementos en dichos pesos. El algoritmo asume que cada peso es independiente de modo que puede alcanzar su valor óptimo sin depender de los demás pesos de la red. |
| | Jacob mejorada | Permite aplicar diferentes incrementos y parámetros para cada uno de los pesos, lo cual representa una ventaja si se requiere ajustarlos con magnitudes diferentes entre ellos. El proceso se realiza automáticamente de modo adaptativo, acelerando la tendencia hacia el error mínimo. |
| Reforzado | Enfriamiento simulado | Utiliza una función de energía cuya minimización permite encontrar el mínimo global. Durante el proceso, la red tiene la misma probabilidad de pasar a estados de alta y baja energía, lo que le permite superar con facilidad los mínimos locales hasta lograr el mínimo global. |
| | Optimización Solis & Wets | Es similar al enfriamiento simulado, pero genera internamente una perturbación aleatoria a los mejores pesos. El desempeño de la red se evalúa mediante el gradiente de una función de costo o de error con respecto a los pesos. |
| | Método de Powell | Requiere alta capacidad de almacenamiento y el proceso se realiza por pasos analizando diferentes direcciones en el espacio. En cada paso se identifica el mínimo en una determinada dirección (una dimensión). El objetivo es aumentar la probabilidad de que cada nueva dirección conduzca hacia una tendencia decreciente hasta encontrar el mínimo global. |
| No supervisado | Kohonen WTA | Se utiliza para problemas de clasificación mediante aprendizaje competitivo; la minimización de la función de entrada se usa como criterio de separación por clases. |

c) **Las funciones de entrada.** Como se indicó anteriormente, se utilizan para ponderar las señales de entrada a cada neurona en función de su correspondiente intensidad o peso. Existen varias opciones de funciones como, la distancia Euclidiana L1, o L2 si se eleva al cuadrado, el producto punto, la suma cuadrática, entre otros.

d) **Tipo de Pre-procesamiento.** Cuando las variables de entrada se encuentran dentro de órdenes de magnitud muy diferentes, o algunas de ellas oscilan dentro de intervalos o muy pequeños o muy amplios, el proceso de ajuste de los pesos puede resultar dispendioso y causar la “saturación” en las salidas de las neuronas y su estancamiento. Para evitar estos problemas, suele convenir algún tipo de pre-procesamiento a los datos de entrada, para ajustarlos dentro de valores apropiados que a la vez satisfagan el intervalo de valores de la función de transferencia seleccionada. Dentro de las opciones más comunes, se suele aplicar expresiones en función de la desviación estándar o de los valores máximo y mínimo de cada variable.

e) **Las funciones de activación o transferencia** actúan para limitar las salidas de una neurona a un intervalo finito. Cuando existen valores grandes de los pesos, la función seleccionada puede intervenir en el aprendizaje, permitiendo o no la modificación. En la Figura 4.3 se muestran las funciones escalón, lineal y sigmoidea en versión bipolar para permitir valores negativos; también puede usarse la función seno, arco-tangente, Gauss, entre otras.

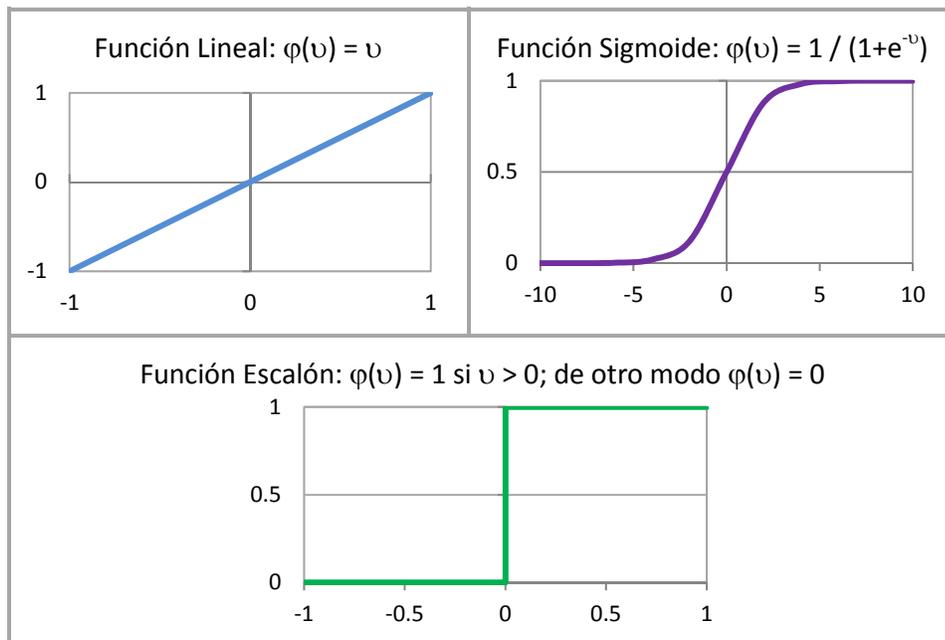


Figura 4.3 Funciones de activación comúnmente usadas

f) **Las funciones de error.** En problemas de clasificación, el error da una idea de la porción de datos clasificada incorrectamente por la RNA. Para tareas de regresión, el error mide las diferencias entre las salidas deseadas y las calculadas por el modelo, utilizando los criterios de minimización mencionados en el numeral 3.2.3, u otros.

Durante el aprendizaje pueden presentarse varias tendencias en el espacio error-tiempo, según se ilustra en la Figura 4.4.

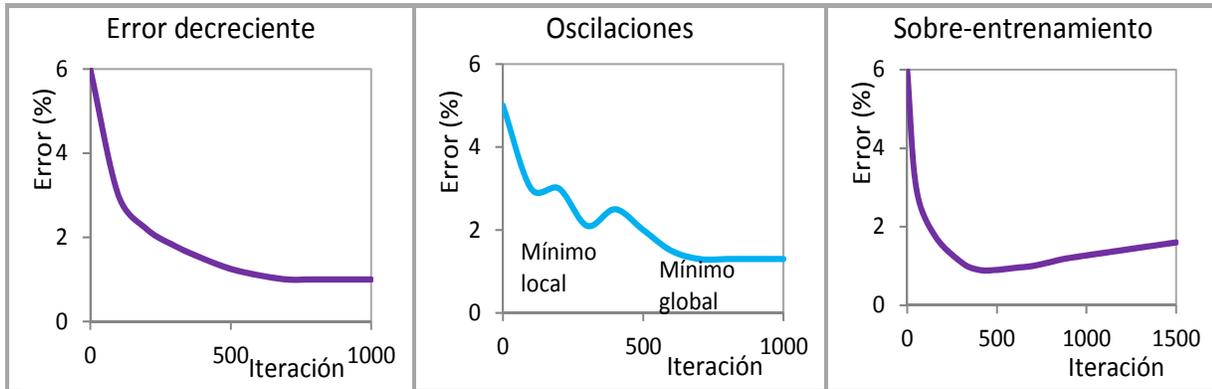


Figura 4.4 Posibles tendencias de la función de error

La tendencia general en el error debe ser decreciente hasta encontrar el criterio pre-establecido, aunque pueden presentarse algunas oscilaciones que constituyen “mínimos locales”. Así mismo, puede darse el caso en que el error cambie de tendencia y se incremente de manera indefinida; se dice entonces que la red está “sobre-entrenada” y comienza a memorizar o a aprender el ruido presente en el conjunto de datos.

4.1.3 Modelación de un problema

La información que se introduce a una RNA para representar algún comportamiento en particular, o extraer información a partir de los datos, constituye el ambiente a partir del cual la red aprenderá a través del entrenamiento. Los datos pueden provenir del conocimiento previo o de mediciones realmente observadas sobre el sistema y el diseño del modelo neuronal se construye a partir de ellos. Esto constituye una diferencia constructiva con los modelos tradicionales, en los cuales primero se adopta una formulación matemática que represente el sistema y la relación entre las variables, y luego se valida el modelo con datos reales.

La información se presenta a la RNA en forma de “ejemplos”. Para tareas supervisadas, cada ejemplo está constituido por un par de vectores de entradas conocidas y salidas deseadas. En tareas no supervisadas, la modelación reconocer patrones a través de los ejemplos presentados en el vector de entrada y como resultado, se obtienen agrupaciones o clases. Para estos fines, se aplica la “regla de similitud”: entradas de la misma clase producen representaciones parecidas dentro de la red. Una medida de la similitud, se obtiene minimizando la función de entrada seleccionada (p.e., la distancia Euclidiana o el producto punto), para aportar criterios de separabilidad; las entradas que pertenezcan a una determinada clase, quedan representadas en la red de manera diferente a aquellas de las demás clases.

El proceso de modelación con RNAs se efectúa mediante dos etapas denominadas de entrenamiento y de prueba, según se describe a continuación:

i) *Etapa de entrenamiento o de aprendizaje.* Una vez introducidos los ejemplos, la red identifica las relaciones entre las variables de entrada - salida (aprendizaje supervisado) asignando valores iniciales a los pesos; con base en dichas relaciones, la red calcula unas salidas y las compara con el comportamiento observado o deseado. Si los valores calculados satisfacen el criterio de aceptación o función de error pre-establecido entre salidas deseadas y calculadas, se dice que la red ha aprendido naturalmente las relaciones entre entradas y salidas; de lo contrario, el algoritmo de aprendizaje seleccionado ajusta los pesos de las conexiones entre las variables y el proceso continua iterativamente. En el aprendizaje no supervisado el proceso se realiza hasta alcanzar la estabilidad, es decir cuando no se identifiquen cambios significativos en los pesos, o se limita el aprendizaje a un determinado número de iteraciones.

ii) *Etapa de prueba.* Evalúa la habilidad de las RNAs para proporcionar salidas o soluciones razonables para nuevos conjuntos de datos; con ello se busca la generalización de manera que el sistema se adapte. Para esos fines, se presentan nuevos conjuntos de variables de entrada a la red, pero no se introduce el correspondiente set de datos de salida; la red calcula unas salidas para los nuevos datos con base en los patrones aprendidos en el entrenamiento.

Aunque en general se encuentra que las redes pequeñas requieren menos datos para alcanzar buenos niveles de generalización, también hay que considerar que a mayor cantidad de datos usados en el entrenamiento, mayor posibilidad de mejorar el desempeño en la etapa de prueba. Cuando se desee obtener un sistema robusto, puede resultar conveniente presentar a la RNA mayor variedad de patrones o a través de los ejemplos.

Vale la pena mencionar que existen parámetros del modelo que se pueden ajustar durante el entrenamiento para mejorar el desempeño de la red cuando se requiera (Haykin 1999). Por ejemplo, el valor de *momentum*, podría llevar el proceso de cambio de pesos a través de uno o más mínimos locales y hacerlos llegar al mínimo global.

Por su parte, *la tasa de entrenamiento* es un factor que proporciona la magnitud del ajuste que se aplica cada vez que se actualiza el peso: una tasa pequeña, puede llevar a una convergencia más lenta y caer en un mínimo local; por el contrario, una tasa alta puede generar oscilaciones o inestabilidad y posiblemente la no convergencia (Owusu-Aabio 1998). Refenes *et al* (1994), encontraron que al combinar valores de *momentum* entre 0.3 y 0.5 y una tasa de entrenamiento de 0.2, se obtienen buenos desempeños de la red. Nii y Attoh-Okine (1999) llegaron a unos resultados bastante similares en un trabajo específico sobre la influencia de estos dos parámetros en el desempeño de redes neuronales entrenadas con algoritmo de retro-propagación.

De cualquier manera, es responsabilidad del analista la prueba y validación adecuada de la modelación para garantizar que la solución corresponde a un mínimo global y no a sobre-entrenamiento o memorización de la RNA.

Cuando se obtienen resultados adecuados o satisfactorios en ambas etapas, se dice la RNA resultante constituye un modelo entrenado, capaz de realizar predicciones o estimaciones confiables y rápidas para conjuntos de datos nuevos o desconocidos.

4.1.4 Evaluación del desempeño de la modelación neuronal

Todos los análisis estadísticos para evaluar la precisión y el desempeño de una red entrenada, se deben reportar con base en los resultados obtenidos en la etapa de prueba, o con nuevos conjuntos de datos introducidos para efectos de validación.

En general, se utiliza la función de error como el principal indicador de precisión de los estimativos. Sin embargo, en las RNAs supervisadas es necesario introducir criterios adicionales para juzgar la calidad de los ajustes entre lo deseado y lo estimado, pues se ha encontrado que varias soluciones pueden proporcionar el mismo error.

Para lograr evaluaciones más completas, resulta útil graficar los valores deseados vs valores pronosticados o estimados y determinar indicadores de ajuste y de correlación; en la práctica común se utiliza el coeficiente de determinación (r^2) aunque éste tampoco resulta suficiente, pues buenas correlaciones no necesariamente reflejan buen nivel de igualdad.

Como elementos adicionales de evaluación, se puede decir que la precisión, correlación y nivel de igualdad entre lo deseado y lo estimado, se da en la medida en que exista un ajuste de tipo lineal entre ellos, que el intercepto de la línea de tendencia sea cercano a cero y que la pendiente de la línea sea cercano a uno.

Pellinen (2001) sugiere los criterios mostrados en la Tabla 4.3 para evaluar la calidad de los ajustes de las RNAs en función de r^2 y de la relación entre el error estándar de los valores pronosticados y la desviación estándar de los valores medidos, Se/Sy ; estos criterios también se consideraron en la investigación de Ceylan *et al* (2009).

Tabla 4.3 Calidad del ajuste entre valores medidos y estimados

| Ajuste | r^2 | Se/Sy |
|-----------|-------------|-------------|
| Excelente | ≥ 0.9 | ≤ 0.35 |
| Bueno | 0.70 – 0.89 | 0.36 – 0.55 |
| Regular | 0.40 – 0.69 | 0.56 – 0.75 |
| Malo | 0.20 – 0.39 | 0.76 – 0.90 |
| Muy malo | ≤ 0.19 | ≥ 0.90 |

Fuente: Pellinen (2001) en Ceylan, Gopalakrishnan y Kim (2009)

4.2 Lógica Difusa - LD

La LD ha resultado útil como una herramienta alternativa para solucionar problemas de clasificación, toma de decisiones, sistemas expertos, análisis de imagen, control, pre-procesamiento de información que contenga datos considerados como erráticos, atípicos o ruidosos, entre muchas otras aplicaciones.

El razonamiento humano involucra procesos lógicos formales e informales. Los primeros utilizan premisas para inferir una conclusión partiendo de lo conocido (o de hipótesis) a lo desconocido; tal conclusión involucra *conceptos rígidos* claramente delimitados como verdadero/falso, válido/no válido, si/no, correcto/incorrecto, cero/uno.

Por su parte el razonamiento informal amplía el espectro de conclusiones, apoyado tanto en las premisas como en la experiencia y el contexto, dando cabida a conceptos poco claros o *difusos* de naturaleza abstracta e imprecisa, para describir ciertos atributos de un sistema o fenómeno. La temperatura, por ejemplo, si bien puede expresarse en el dominio de los números reales, es muy común expresarla en términos lingüísticos con atributos como alta, media o baja.

En la búsqueda de soluciones a ciertos problemas que involucran términos lingüísticos, las nociones difusas no quedan incluidas en los métodos de análisis tradicionales utilizados en medios computacionales. Para superar esta dificultad, se han desarrollado diversas herramientas basadas en la *lógica difusa – LD*, la cual provee un marco para involucrar información cualitativa que tiene implícito algún grado de incertidumbre y subjetividad de manera que pueda formularse matemáticamente y ser procesada en medios computacionales de forma similar al razonamiento humano (Zadeh 1984). Con estas herramientas es posible tratar tanto con la *vaguedad* como con la *ambigüedad*; la primera está asociada con la dificultad de definir fronteras precisas en problemas de agrupamiento y la segunda se relaciona con la dificultad de tomar decisiones cuando se cuenta con varias opciones.

4.2.1 Conjuntos difusos

Zadeh (1965) introdujo inicialmente la teoría de los conjuntos difusos, en la cual se basan muchos de los conceptos y aplicaciones posteriores apoyados en la LD. En las representaciones difusas, una variable lingüística tiene un conjunto de términos que la describen. Cada uno de estos términos está definido por un rango de valores reales y cada valor tiene asociado un grado de verdad o de pertenencia a su respectivo conjunto.

El grado de verdad se expresa como un continuo de números reales que pueden tomar valores entre cero y uno, creando una transición gradual entre la no pertenencia a un conjunto (cero) y la pertenencia total (uno), lo cual se puede generalizar mediante una “función de pertenencia” con la siguiente notación:

$$\mu_{mf}(x)$$

Siendo:

μ = El grado de pertenencia

mf = nombre de la función de pertenencia (membership function)

X = posibles valores que toma la variable representada en el eje horizontal.

A manera de ejemplo, en la Figura 4.5 se ilustra la representación de una variable desde la lógica clásica y las formas de funciones de pertenencia más comunes que pueden representarla mediante la lógica difusa. Se ha seleccionado una variable asociada con el tema de investigación, de manera que los fundamentos expuestos en este capítulo sirvan para interpretar y comprender mejor el modelo que se plantea en capítulos posteriores.

La variable lingüística seleccionada es la *condición de un pavimento* en términos del % de área afectada por grietas por fatiga; el eje horizontal de la Figura 4.5 representa el dominio físico o recorrido universal donde la variable toma sus valores; el conjunto de términos asociado a la variable sería *adecuada*, *marginal* e *inadecuada*, según los valores recomendados en la Tabla 3.7 (condición adecuada si el área es menor del 5%; marginal si está entre 5 y 20 %; inadecuada si es mayor de 20%).

Según se observa en la Figura 4.5 (b y c), una variable puede tener diferentes formas de representación difusa; las funciones triangular y trapezoidal aportan simplicidad computacional, mientras que funciones como la exponencial y gaussiana, aportan transiciones más suaves.

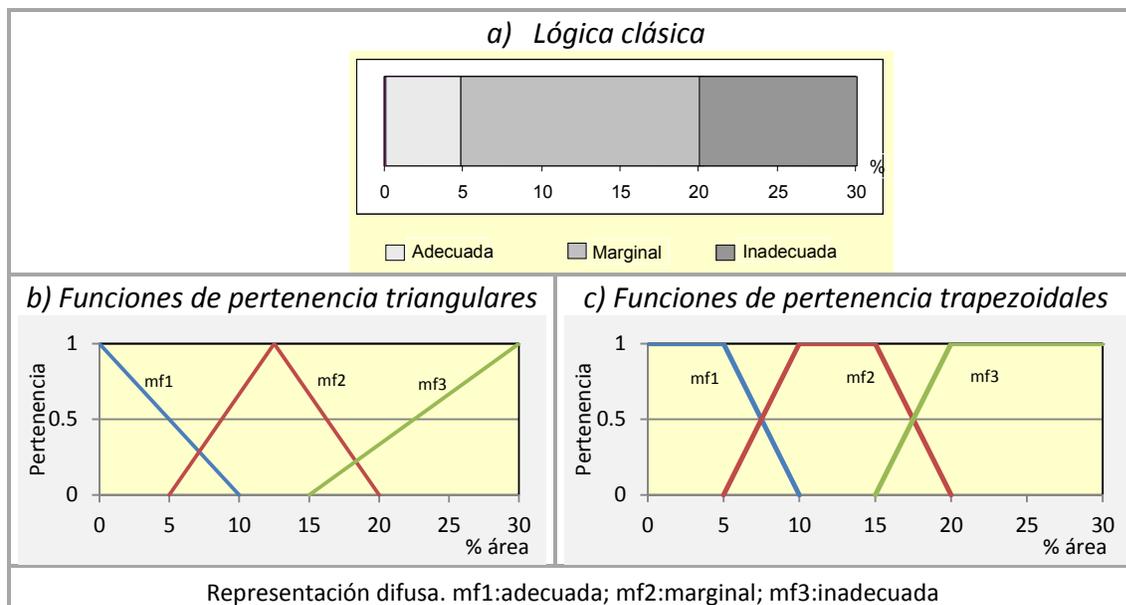


Figura 4.5 Representación clásica y difusa de una variable.

La selección de la mejor representación y la definición de los valores que pueden tomar las funciones de pertenencia, depende en principio de la experiencia y el conocimiento de las variables que se estén analizando; para el refinamiento de las representaciones definidas por

expertos, se puede utilizar el aprendizaje adaptativo mediante redes neuronales. Esta misma técnica puede utilizarse incluso para deducir las funciones de pertenencia cuando no se cuenta con la experiencia, pero sí con suficiente información numérica.

A continuación se describe la interpretación de las funciones de pertenencia trapezoidales mostradas en la Figura 4.5c). Para ello, se analizan las condiciones *adecuada* y *marginal* de la variable condición por grietas, cuyo detalle se ilustra en la Figura 4.6.

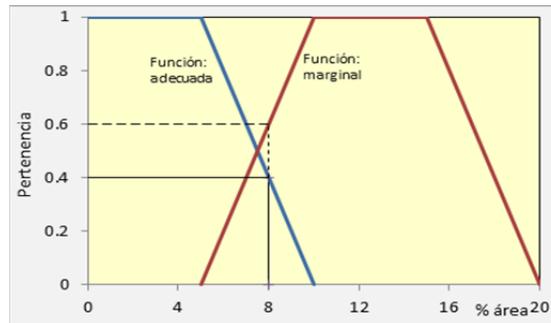


Figura 4.6 Interpretación de las funciones de pertenencia - condición por grietas

Se observa que cuando el área con grietas está entre 0 y 5% (pavimento con muy poco o nulo agrietamiento), existe una pertenencia 1 o total a la condición adecuada ($\mu_{\text{adecuada}}(0\%) = 1$; $\mu_{\text{adecuada}}(5\%) = 1$); en este caso, un valor de 5% de grietas y *condición adecuada* no son lo mismo, pero si están asociados mediante un valor de pertenencia. Si el área con grietas es del 10%, hay un grado de pertenencia cero a esa condición ($\mu_{\text{adecuada}}(10\%) = 0$); es decir que con ese nivel de grietas, un pavimento deja de considerarse adecuado.

Para agrietamientos intermedios entre 5% y 10%, la pertenencia a la condición adecuada baja gradualmente de uno a cero; un área de 8% por ejemplo, tiene una pertenencia de 0.4 a esa condición ($\mu_{\text{adecuada}}(8\%) = 0.4$).

Igualmente, se observa que las funciones de pertenencia pueden traslaparse de manera que para algunos valores, una variable quede asociada a dos atributos diferentes con cierto grado de pertenencia a cada uno de ellos. Para el ejemplo que se viene mencionando, un área de 8%, también tiene 0.6 de pertenencia a la condición marginal ($\mu_{\text{marginal}}(8\%) = 0.6$); de esta manera, en la medida en que el área agrietada se incrementa de 5% a 10%, el pavimento va dejando de ser adecuado, para irse considerando con condición marginal.

4.2.2 Reglas de inferencia difusa y operaciones entre conjuntos

Mediante el razonamiento aproximado, los conjuntos difusos pueden articularse a través del método de inferencia denominado *Modus Ponens*, para definir reglas difusas estructuradas con *premisas* y *consecuencias* del tipo SI-ENTONCES, útiles para aplicar conocimiento y experiencia hacia problemas de toma de decisiones, sistemas expertos y clasificación. Las reglas difusas se

definen como aquellas en las cuales los antecedentes y los consecuentes están compuestos por declaraciones difusas; la estructura de una regla difusa está sujeta regularmente a la interpretación que haga el analista o un experto sobre las variables del modelo. Para el ejemplo que se ha venido tratando una regla de inferencia difusa podría ser:

| | |
|--|---|
| SI el agrietamiento es adecuado | ENTONCES no aplique sello al pavimento |
| <i>Premisa</i> | <i>Consecuencia</i> |

También pueden plantearse reglas de inferencia del tipo SI... Y / Q ... ENTONCES..., cuya consecuencia depende de varias premisas que pueden estar asociadas a la misma variable (agrietamiento), tal como se indica a continuación:

| | | |
|--|-------------------|--|
| SI el agrietamiento es adecuado | <u>Q</u> marginal | ENTONCES aplique conservación local |
| <i>Premisa 1</i> | <i>Premisa 2</i> | <i>Consecuencia</i> |

Para representar el operador lógico Q entre las premisas, se pueden introducir una operación básica de *unión* entre conjuntos difusos, según se ilustra en la Figura 4.7.

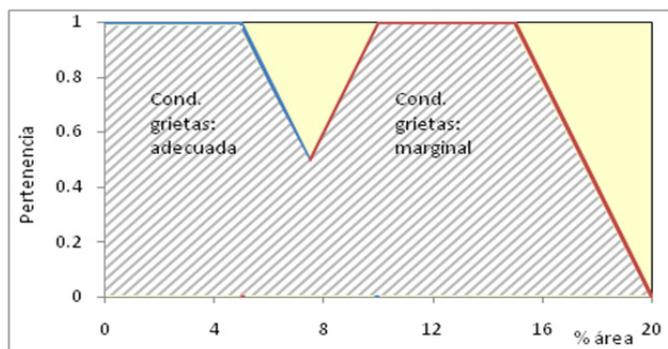


Figura 4.7 Operador O - unión de conjuntos

Como se observa, esta operación genera la *agregación* o *implicación máxima* (máx) entre los dos conjuntos; la notación de esta regla se expresa de la siguiente forma:

Premisa 1: $\mu_{\text{adecuada}}(X)$

Premisa 2: $\mu_{\text{marginal}}(X)$

Operación: $\mu_{\text{adecuada}}(X) \text{ } \underline{Q} \text{ } \mu_{\text{marginal}}(X)$

Notaciones: $\text{máx}(\mu_{\text{adecuada}}(X), \mu_{\text{marginal}}(X)); \mu_{\text{adecuada}}(X) \cup \mu_{\text{marginal}}(X); \mu_{\text{adecuada}}(X) \vee \mu_{\text{marginal}}(X);$

De otro lado y con el ánimo de ilustrar la representación del operador Y, se considera un ejemplo donde la consecuencia depende de varias premisas asociadas con diferentes variables:

| | | |
|--|------------------------------------|---------------------------------------|
| SI el agrietamiento es adecuado | Y los baches son marginales | ENTONCES aplique parcheo local |
| <i>Premisa 1</i> | <i>Premisa 2</i> | <i>Consecuencia</i> |

En este ejemplo, es necesario plantear primero los conjuntos difusos asociados con la variable *condición por baches* y sus respectivas funciones de pertenencia. En la Figura 4.8 se proponen tales representaciones teniendo en cuenta los valores sugeridos en la Tabla 3.8 (condición adecuada si el área afectada es menor de 8%; marginal si está entre 8 y 15 %; inadecuada si es mayor de 15%).

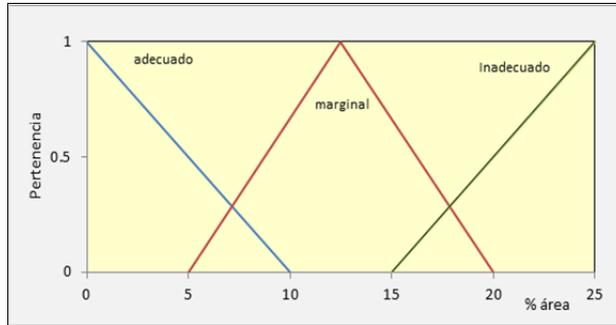


Figura 4.8 Representación difusa de la variable condición por baches

El operador **Y** entre las dos premisas, implica una operación básica de intersección entre conjuntos difusos, obteniendo la representación indicada en la Figura 4.9. En este caso, se genera la *implicación mínima* entre los dos conjuntos (min).

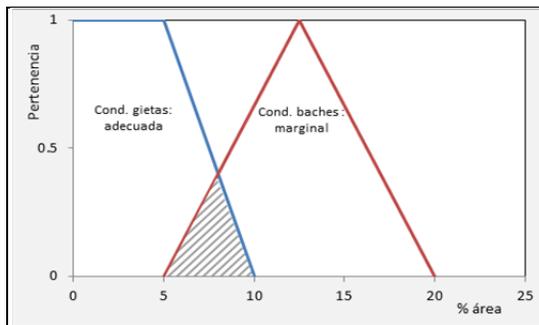


Figura 4.9 Operador Y - intersección entre conjuntos

Vale la pena resaltar que en los ejemplos anteriores la *consecuencia* de cada regla es una toma de decisión expresada en términos lingüísticos. En otros casos, como en problemas de clasificación, la consecuencia se representa además en términos difusos; por tanto, deben definirse previamente las clases, el dominio físico de cada una de ellas y sus correspondientes funciones de pertenencia.

Para ilustrar este último caso, se plantea otro ejemplo donde se clasifica la condición de un pavimento en función del área afectada por grietas y por baches. La variable *condición del*

pavimento representa la consecuencia y tiene asociado un conjunto de términos como el mostrado en la Figura 4.10. Aquí, la condición se ha clasificado en categorías a las cuales se les ha asignado un cierto rango de valores con sus respectivas funciones de pertenencia.

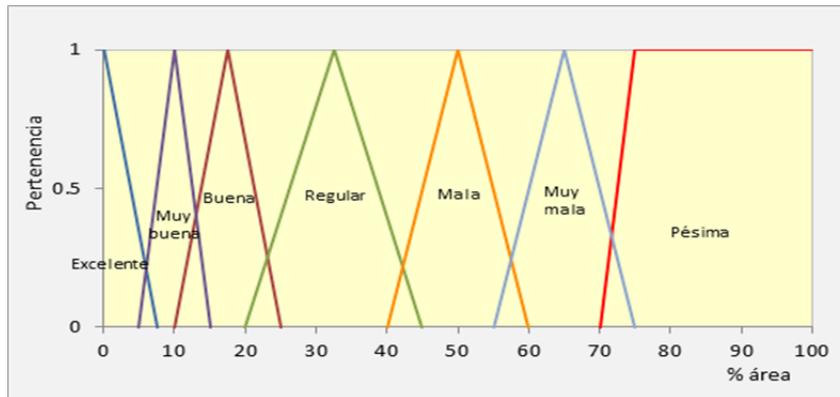


Figura 4.10 Variable consecuente difusa: condición de un pavimento

Cada una de estas clases representa una variedad de combinaciones de % de área afectada por grietas y % de área con baches, de modo que la condición resultante del pavimento integra los grados de afectación de los dos tipos de daños, expresada también en términos de % área. Planteando ahora la siguiente regla:

| | | |
|--|--------------------------------|---------------------------------------|
| SI el agrietamiento es adecuado | Y los baches marginales | ENTONCES la condición es buena |
| <i>Premisa 1</i> | <i>Premisa 2</i> | <i>Consecuencia</i> |

En el caso específico donde se quiere clasificar un pavimento que exhibe 8% del área con grietas y 15% del área con baches, la representación gráfica de los grados de pertenencia de cada componente de la regla se ilustra en la Figura 4.11.

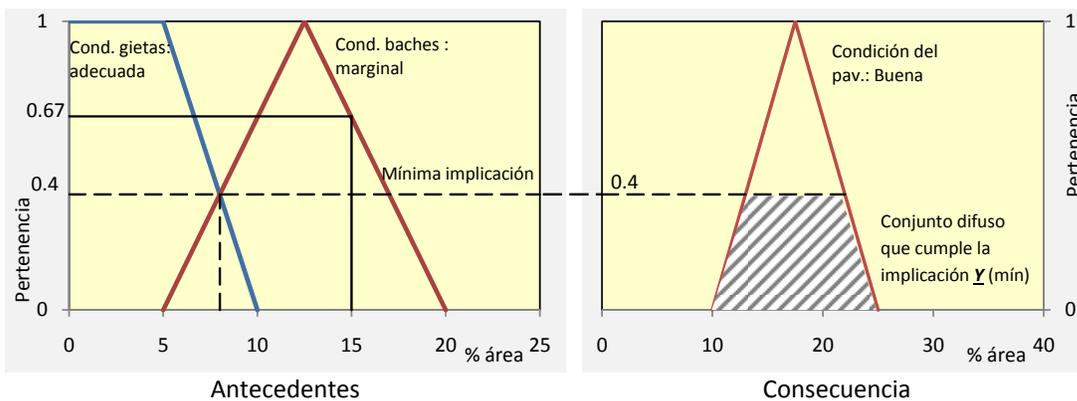


Figura 4.11 Regla difusa con implicación Y

La notación de esta regla y sus componentes, se expresa de la siguiente forma:

Premisa 1: $\mu_{\text{adecuada}}(8\%) = 0.4$

Premisa 2: $\mu_{\text{marginal}}(15\%) = 0.67$

Operación: $\mu_{\text{adecuada}}(8\%) \underline{Y} \mu_{\text{marginal}}(15\%) = 0.4$

Otras notaciones empleadas:

$$\min[\mu_{\text{adecuada}}(8\%), \mu_{\text{marginal}}(15\%)] = 0.4$$

$$\mu_{\text{adecuada}}(8\%) \wedge \mu_{\text{marginal}}(15\%) = 0.4$$

$$\mu_{\text{adecuada}}(8\%) \cap \mu_{\text{marginal}}(15\%) = 0.4$$

En este ejemplo, el grado de verdad de la regla corresponde al mínimo valor de verdad de sus premisas (0.4) y la representación difusa de la consecuencia queda truncada en ese valor.

4.2.3 Sistemas de inferencia difusa - SIDs

Los Sistema de Inferencia Difusa - SIDs, (FIS, por sus siglas en inglés), utilizan la LD tanto para representar diferentes formas del conocimiento como para modelar las interacciones y relaciones entre variables de un sistema, las cuales tienen un dominio físico de números reales producto de la observación, pero se expresan en términos lingüísticos con base en el conocimiento y la experiencia. Estos sistemas resultan útiles en problemas donde las soluciones dependen de muchas variables que tienen diversos atributos, pues tienen la capacidad de procesar múltiples reglas de premisas y consecuencias simultáneamente.

En el proceso de inferencia, se formula la correspondencia entre variables de entrada y la salida del sistema utilizando la lógica difusa. Esta relación proporciona una base desde la cual se pueden tomar decisiones o identificar patrones, involucrando todos los elementos descritos anteriormente: funciones de pertenencia, los operadores de lógica difusa y las reglas difusas.

Para la solución de problemas de ingeniería, se utilizan los sistemas propuestos por Mandami y Takagi-Sugeno-Kang (en Cordón *et al*, 2001). Los dos sistemas tienen como entrada un conjunto de variables con sus respectivos dominios en la escala de números reales y llegan a unas soluciones expresadas también en términos de números reales. La diferencia entre los dos métodos, radica en la forma en que se determinan las salidas.

El sistema de Mandami (Mandami y Assilian, 1975), también denominado controlador difuso, presenta la estructura básica ilustrada esquemáticamente en la Figura 4.12, cuyos componentes se describen a continuación.

- a) La base de datos que contiene los términos lingüísticos asociados a las variables de entrada y los correspondientes significados.
- b) El grupo de reglas lingüísticas que articulan las variables, conformadas por premisas y consecuencias.

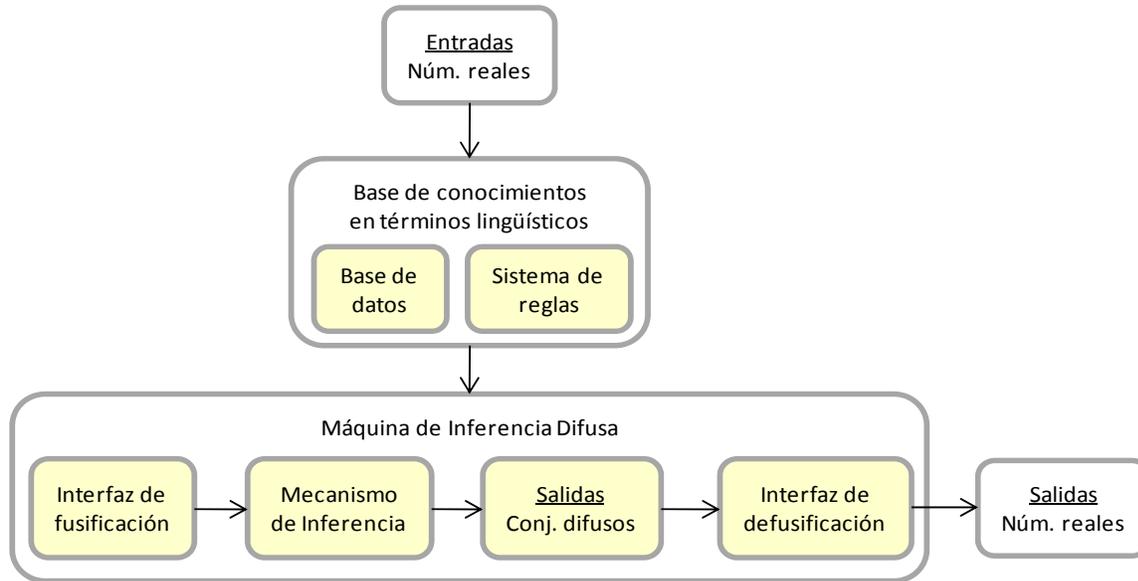


Figura 4.12 Estructura general del SID propuesto por Mandami

c) Una interfaz de “fusificación” donde cada variable de entrada y los componentes de cada regla se expresan como conjuntos difusos, con sus correspondientes funciones de pertenencia. Como se mencionó anteriormente, estas funciones pueden definirse aplicando la opinión de expertos, métodos automáticos de aprendizaje adaptativo o ambos.

d) El mecanismo de inferencia que permite llegar a una conclusión o consecuencia razonable en función de las premisas. Si una premisa de una regla tiene un grado de verdad no-nulo, la regla se activa en el sistema y se genera una salida para cada regla; el sistema de Mandami utiliza la implicación mínima (mín) para generar la salida de cada regla.

e) La salida del sistema de inferencia. Dado que es posible activar varias reglas simultáneamente en el sistema, la salida global estará conformada por la *agregación* de las consecuencias individuales de todas las reglas, utilizando la máxima implicación (máx); al final de la secuencia de reglas, se obtiene un subconjunto difuso para cada una de las variables de salida.

f) Una interfaz de “defusificación”. En ciertas aplicaciones se requiere obtener un escalar que represente las salidas. Esto es posible mediante la aplicación de técnicas de defusificación, tales como el centro de gravedad, la bisección del área, entre otros. El primero consiste en hallar el centro de gravedad del conjunto difuso y proyectarlo hacia el eje horizontal en la gráfica de la salida vs grado de pertenencia, con lo cual se obtiene el valor numérico representativo del conjunto difuso. La bisección del área representa la proyección de la línea que divide el conjunto difuso de la salida en áreas iguales hacia la derecha e izquierda.

Para ilustrar mejor los últimos pasos del sistema descrito, se plantea el siguiente ejemplo: Se tiene un sistema de tres reglas difusas, cuyas consecuencias se ilustran en la Figura 4.13a. Para

obtener la salida global de este conjunto de reglas, Mandami utiliza la máxima implicación obteniendo el subconjunto difuso mostrado en la Figura 4.13b. Aplicando el centro de gravedad-CG y la bisección de área como métodos de defusificación, se obtienen valores numéricos de 16% y 20%, respectivamente.

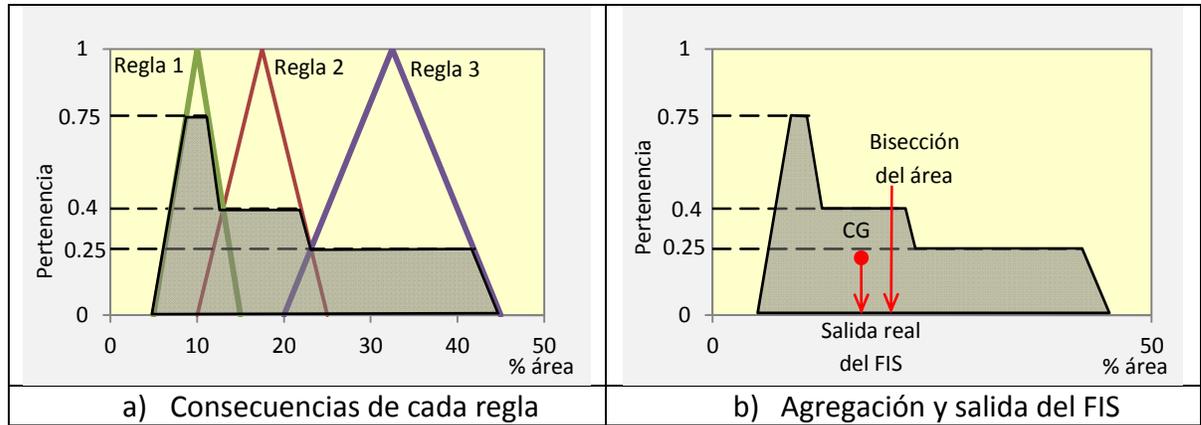


Figura 4.13 Mecanismo de inferencia y defusificación en el SID de Mandami.

El sistema **Takagi-Sugeno-Kang** (1985, 1988), tiene la estructura general mostrada en la Figura 4.14, que aunque resulta muy similar a la de Mandami, tiene un sistema de reglas diferente lo cual afecta la forma en que se presentan las salidas del sistema.

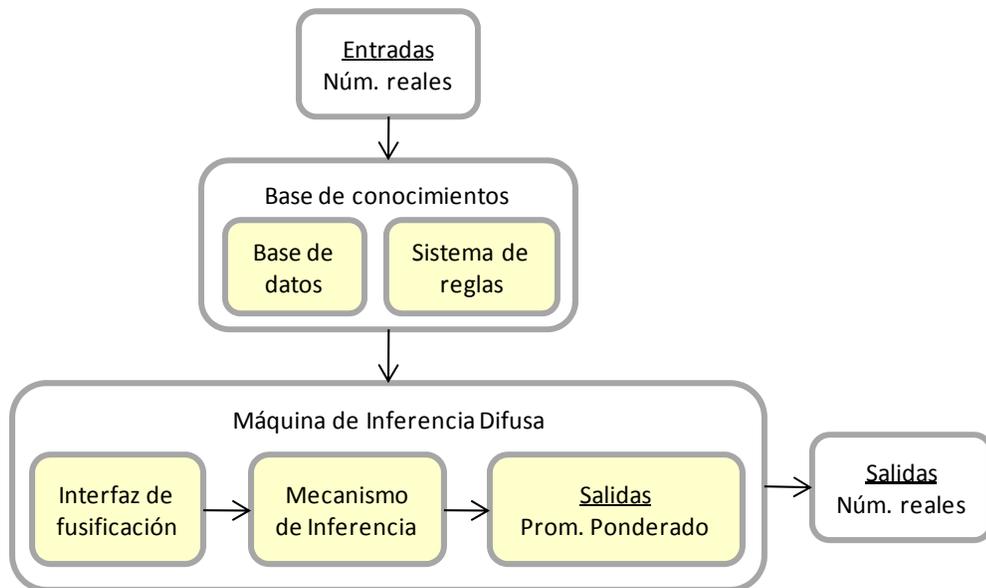


Figura 4.14 Estructura general del SID TSK

Las reglas del sistema TSK poseen una estructura en la cual los antecedentes están compuestos por variables lingüísticas y las consecuencias son funciones dependientes de las variables de entrada, como se indica a continuación.

| | | |
|------------------------------|-----------------------------|--|
| SI X_1 es ... A_1 | Y X_n es ... A_n | ENTONCES $Y_i = f(X_1, \dots, X_n)$ |
| <i>Premisa 1</i> | <i>Premisa n</i> | <i>Consecuencia</i> |

X_1 a X_n , son las variables lingüísticas de entrada; A_1 a A_n son términos difusos asociados a las variables de entrada; Y es la variable de salida de la regla i . La representación más común de este tipo de reglas es aquella en la cual la consecuencia es una combinación lineal de las variables de los antecedentes, según la siguiente expresión:

$$Y_i = p_0 + p_1 * X_1 + \dots + p_n * X_n$$

Siendo p_0 a p_n números reales. De esta forma, la salida de cada regla queda expresada como una ecuación, de modo que en un sistema conformado por una cierta cantidad de reglas m , se genera un sistema de ecuaciones que puede solucionarse mediante métodos tradicionales para obtener los coeficientes p_0 a p_n .

La salida global de un sistema TSK, se obtiene mediante el promedio ponderado de las salidas de las reglas implicadas, dado por la siguiente ecuación:

$$\frac{\sum_{i=1}^m h_i * Y_i}{\sum_{i=1}^m h_i}$$

Donde h_i resulta de combinar los antecedentes de cada una de las reglas del sistema, mediante la implicación mínima expresada como:

$$h_i = \text{mín}(\mu_{A_1}(X_1), \dots, \mu_{A_n}(X_n))$$

Dada la estructura de las reglas de inferencia, el uso de los sistemas TSK se encuentra limitado en aquellos problemas en los cuales se requiere involucrar el conocimiento de expertos en las salidas de cada regla y en la salida global del sistema. Aunque se pueden realizar modificaciones en los consecuentes para asociar de algún modo los coeficientes p_0 con representaciones difusas, no se logra utilizar el alcance pleno de la LD en este tipo de problemas.

En síntesis, un SID es un modelo que representa las variables de entradas de un problema, como funciones de pertenencia y éstas a su vez como reglas difusas; las reglas se relacionan con un conjunto de variables de salida, las cuales quedan representadas como funciones de pertenencia o como una combinación lineal, para finalmente traducirse a un valor real de la salida o una decisión asociada con la misma.

Las principales aplicaciones de los SIDs han estado enfocadas hacia la solución de problemas de control, toma de decisiones, clasificación y modelación. En este último caso, los SIDs constituyen una alternativa interesante a los modelos paramétricos tradicionales que definen relaciones entre variables, introduciendo flexibilidad y de alguna manera una interpretación

más simple del comportamiento de un fenómeno a través del sistema de reglas. Esto es posible gracias a que cada regla representa un modelo local fácilmente analizable y cualquier cambio en alguna de ellas, solo afecta la aproximación en ese campo local, sin alterar significativamente la aproximación global del sistema.

4.2.4 Agrupamiento difuso

En problemas de clasificación la tarea consiste en identificar patrones diferentes en un conjunto de datos para producir una representación concisa de comportamiento de un sistema. Las herramientas difusas permiten encontrar grupos o clases, mediante aproximaciones tales como FCM (Fuzzy C-means), generalizada por Bezdek (1981) y el agrupamiento sustractivo (Doan, *et al.* 1994); éste último resulta útil para estimar el número de grupos y los centros aproximados de cada uno, cuando no se tiene idea de la cantidad de grupos que pueden formarse a partir del conjunto de datos disponibles.

El método FCM por su parte, divide el espacio multidimensional del conjunto de datos en un número determinado de grupos diferentes; para ello, supone la posición media inicial de los centros de cada grupo y asigna a cada dato un grado de pertenencia a determinado grupo. Mediante iteraciones sucesivas, se van ajustando los centros y los grados de pertenencia, hasta encontrar la ubicación correcta de los mismos. En la iteración se busca minimizar una función objetivo que representa la distancia desde cualquier punto de los datos al centro del grupo, ponderado por grado de pertenencia de ese dato.

Cada uno de los centros representa un grupo de datos o conjunto de típicos, por lo que un solo elemento puede sustituir los miembros de dicho grupo; con ello se eliminan datos redundantes generando una disminución en el número global de datos para análisis; por esta razón el agrupamiento difuso se ha visto como un método útil para el pre-procesamiento de información. Los datos que no queden asignados a un determinado grupo, corresponden a los atípicos o no agrupables y dependiendo del tipo de problema, pueden ser involucrados o no dentro de los análisis.

4.3 Sistemas basados en RNAs y LD

Mediante la integración de sistemas neuronales y difusos se logra complementar las habilidades de cada técnica y superar las deficiencias individuales, según se indica en la Tabla 4.4; esta sinergia ha permitido el desarrollo de sistemas inteligentes para resolver problemas específicos en varias aplicaciones, combinando la capacidad de la LD para representar el conocimiento y manejar la incertidumbre, con la habilidad de las RNAs para aprender relaciones entre datos de entrada y salida.

Al fusionar o combinar las dos técnicas para construir un sistema integrado, resultan arreglos más complejos que los de un FIS, tales como los sistemas neuro-difusos, híbridos u otros, dependiendo de la forma en que se relacionen y las tareas que cada técnica realice (Lin y Lee, 1996; Abraham, 2001).

Tabla 4.4 Comparación entre sistemas basados en RNAs y sistemas difusos

| Característica | FIS | RNAs |
|-----------------------------------|-------|-------------------|
| Capacidad de aprendizaje | Mala | Buena |
| Representación del conocimiento | Buena | Mala |
| Integrar conocimiento de expertos | Buena | Mala |
| No linealidad | Buena | Buena |
| Habilidad de optimización | Mala | Ligeramente buena |
| Tolerancia a fallas | Buena | Buena |
| Tolerancia a incertidumbre | Buena | Buena |
| Operación en tiempo real | Buena | Ligeramente buena |

Fuente: Fukuda and Shibata, 1994 en Lin y Lee, 1996

En los **sistemas neuro-difusos**, las RNAs se usan para pre-procesar datos, constituyendo una herramienta de apoyo para los modelos difusos. En estas aproximaciones, las RNAs se emplean generalmente para aprender o refinar automáticamente las funciones de pertenencia y el sistema de reglas de modelos difusos, a partir del ejemplo. Al introducir posteriormente tales reglas y funciones de pertenencia dentro de un FIS, éste mejora su desempeño y el costo computacional.

En los **sistemas híbridos** las dos técnicas se complementan para alcanzar un objetivo común, pero trabajan separadamente como dos subsistemas desacoplados que realizan sus propias tareas al servicio de diversas funciones en el sistema combinado (Lin y Lee, 1996). Uno de los sistemas híbridos más conocidos es el ANFIS - Adaptive-Network-based Fuzzy Inference System desarrollado por Jang (1993), definido como un sistema de inferencia difusa incorporado en el marco de una red neuronal adaptativa. Por su arquitectura, se ha visto como una clase de red neuronal funcionalmente equivalente a un sistema de inferencia difusa; Gopalakrishnan (2010) describe el ANFIS como un sistema de RNA multicapa que tiene en cuenta los elementos básicos y las funciones de los sistemas difusos tradicionales, pero soportado en el modelo de inferencia TSK.

El ANFIS puede construir las relaciones entradas-salidas basado tanto en el aprendizaje de las condiciones de parejas de datos, como en el conocimiento humano, razón por la cual ha resultado apropiado en múltiples aplicaciones. Sin embargo, su desempeño se ha visto afectado cuando existe una gran cantidad de patrones de entrada-salida, cuando el espacio de las entradas tiene una partición muy detallada (Goktepe *et al*, 2005), o cuando la base de datos contiene información bastante ruidosa o con datos atípicos, caso en el cual es necesaria la validación del modelo.

La conveniencia del uso de las RNAs para definir las funciones de pertenencia a utilizar dentro de un SID, ha sido un tema bastante discutido. Por una parte, se ha mencionado que los mecanismos de aprendizaje no deben ser aplicados a la determinación de las funciones de pertenencia de conceptos que transmiten una descripción lingüística y subjetiva. Ante esto, Jang

(1993) menciona que la pertinencia de su aplicación queda a juicio del analista dependiendo de la situación, según se describe a continuación.

Si la base de datos disponible es muy pequeña y no contiene información suficiente que describa el sistema en consideración, el conocimiento de los expertos representa la fuente principal para definir las funciones de pertenencia y las reglas difusas; en este caso no es conveniente el uso de sistemas automáticos de aprendizaje para definir o refinar las funciones definidas por expertos, pues difícilmente podría reflejarse su conocimiento y la experiencia en las salidas deseadas.

Por el contrario, si la base de datos disponibles de entrada-salida es suficientemente grande, el refinamiento de las funciones de pertenencia mediante el aprendizaje adaptativo resulta aplicable y algunas veces necesario, si se quiere eliminar la subjetividad asociada con las diferencias de experto a experto en la definición de tales funciones.

5 PLANTEAMIENTO METODOLÓGICO Y CASO APLICADO

La construcción de una metodología apropiada para abordar la evaluación estructural de pavimentos en servicio, se apoyó en tres elementos básicos, donde convergen prácticas tradicionales, herramientas de la inteligencia computacional y tendencias actuales de ingeniería de pavimentos.

| FUNDAMENTACIÓN TEÓRICA | INVESTIGACIONES PREVIAS | EXPERIENCIA Y PRÁCTICA |
|--|---|--|
| <p>Ingeniería de Pavimentos Materiales, comportamiento mecánico, auscultación no destructiva, evaluación de pavimentos en servicio, modelos de deterioro, sistemas de administración de carreteras.</p> <p>Inteligencia Artificial Lógica Difusa y Redes</p> | <p>Publicaciones en bases de datos especializadas.</p> <p>Estado del conocimiento: avances logrados en el tema específico de investigación.</p> | <p>Vías terrestres: evaluación y gestión de pavimentos en México; revisión de casos aplicados; recomendaciones de expertos sobre valores típicos de parámetros de comportamiento, indicadores de condición y soluciones exitosas.</p> <p>Inteligencia Artificial: consultas a expertos en aplicación de software especializado - RNA y LD.</p> |

Con base en estos tres elementos, se plantea conceptualmente el proceso mostrado en la Figura 5.1, a través de cinco etapas. Las dos primeras, se desarrollan mediante análisis y prácticas convencionales. En las tres últimas, se propone la aplicación de la inteligencia artificial para solucionar problemas específicos: en la etapa 3 se diseñan modelos neuronales para la identificación de parámetros mecánicos tales como módulos de capa y relaciones de Poisson; en las etapas 4 y 5 se diseñan sistemas de inferencia difusa para evaluar la rigidez y deterioro de un corredor y para formular soluciones en función de la condición estructural integral. En la etapa 5, también se aplican modelos de deterioro para estimar la vida remanente.

A continuación se describe en detalle la metodología desarrollada y su aplicación a un caso de estudio, especificando las herramientas utilizadas en cada una de las etapas planteadas.

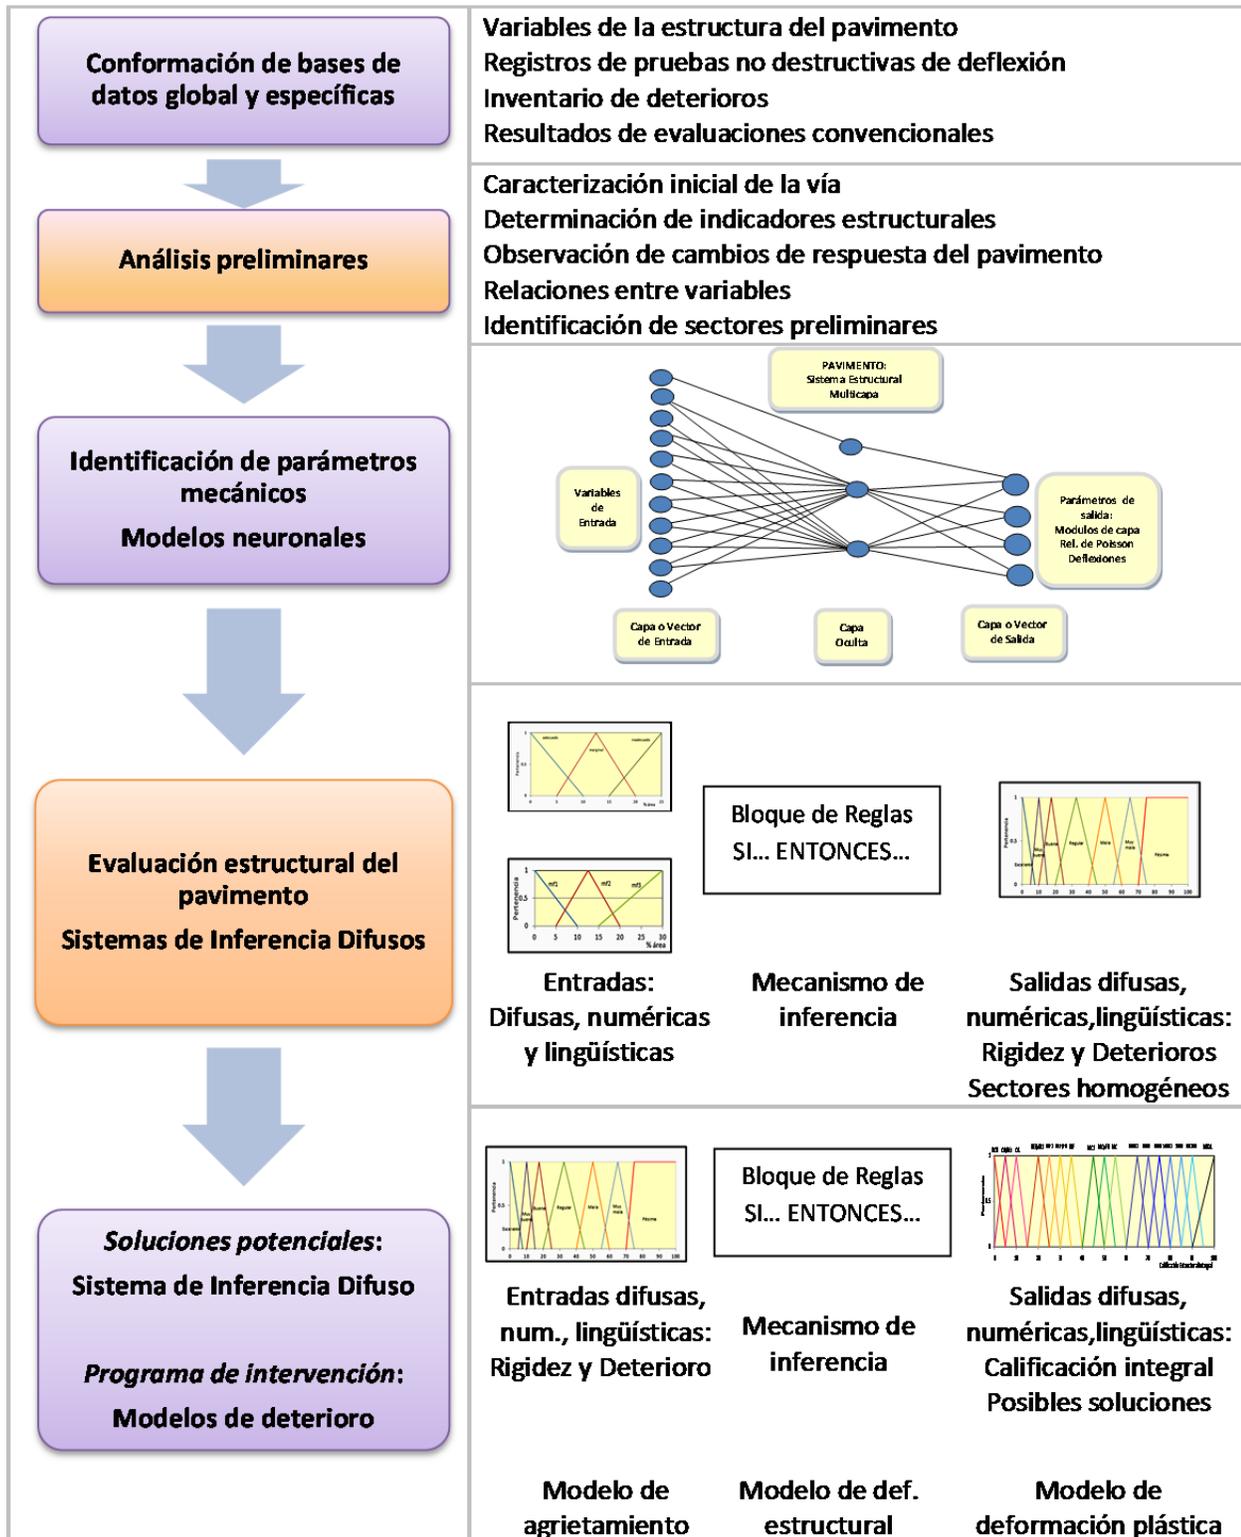


Figura 5.1 Proceso metodológico desarrollado

5.1 Conformación de las bases de datos

Como caso de estudio, se seleccionó uno de los cinco corredores viales evaluados por métodos convencionales en la investigación de Orozco (2005), cuya información técnica resulta suficientemente representativa para realizar la evaluación estructural del pavimento; con ello se busca contar con un marco de referencia para poder comparar y de alguna manera validar las modelaciones propuestas en esta investigación.

El tramo seleccionado, Acayucan-Límite entre Estados de Veracruz y Oaxaca de la carretera Coatzacoalcos–Salina Cruz, se muestra en la Figura 5.2; está conformado por una calzada con dos carriles, posee una longitud de 28 km comprendida entre el k112 y el k140 y maneja alrededor de 5000 vehículos/día, con una composición de 73% de autos, 8% de buses y 19% de camiones; éstos últimos se distribuyen en 42% camiones de dos ejes, 16% de tres ejes, 13% de 5 ejes, 19% de 6 ejes y 11% de más de 6 ejes. Atraviesa zonas planas con alturas de 50 a 130 m.s.n.m., temperatura media de 26° C y precipitación media de 140 mm/mes.



Fuente: Adaptada de google maps; google eart

Figura 5.2 Ubicación del tramo vial seleccionado y sección típica

En la construcción de la base de datos global se incluye toda la información técnica disponible para la evaluación, clasificando las variables según su tipología tal como se muestra en la Tabla 5.1. A partir de la base global, se construyen las bases de datos específicas para realizar los análisis particulares planteados en las diferentes etapas de la metodología.

Tabla 5.1 Bases de datos global y específicas

| Tipo de información | Variables | Etapa II | Etapa III | Etapa IV | Etapa V |
|--|--|-------------|-------------|-------------|-------------|
| Estructura del pavimento: * Sondeos cada Km | Espesores de 3 y 4 capas (M/N) Material de cada capa (L) | √ √ | √ √ | √ √ | |
| Pruebas de deflexión c/200 m: * 278 en carril derecho * 280 en carril izquierdo | Carga aplicada, 1 por prueba (M/N) Deflexiones, 7 por prueba (M/N) Posición sensor, 7 por prueba (M/N) | √ | √ √ √ | √ | |
| Indicadores estructurales: A partir de cuencas de deflexión | Índice estructural, área cuenca (C/N) Factores de forma (C/N-L) | √ √ | | √ √ | |
| Parámetros de comportamiento | Módulos de capa T. elástica (C/N) Relación de Poisson (A-C/N) | √ | √ √ | | |
| Deterioro estructural: Magnitud y severidad | Rodera, c/20m/huella/carril (M/N-L) Grietas y ondulaciones (M/N-L) Baches abiertos y reparados (M/N-L) | √ √ √ | | √ √ √ | √ √ √ |
| Conocimiento de expertos y estudios previos | Valores típicos parámetros (A/N-L) Recomendaciones intervención (A/L) | | | √ | √ |
| Condiciones operativas | Tránsito (N), clima(N), otros. | √ | | | √ |

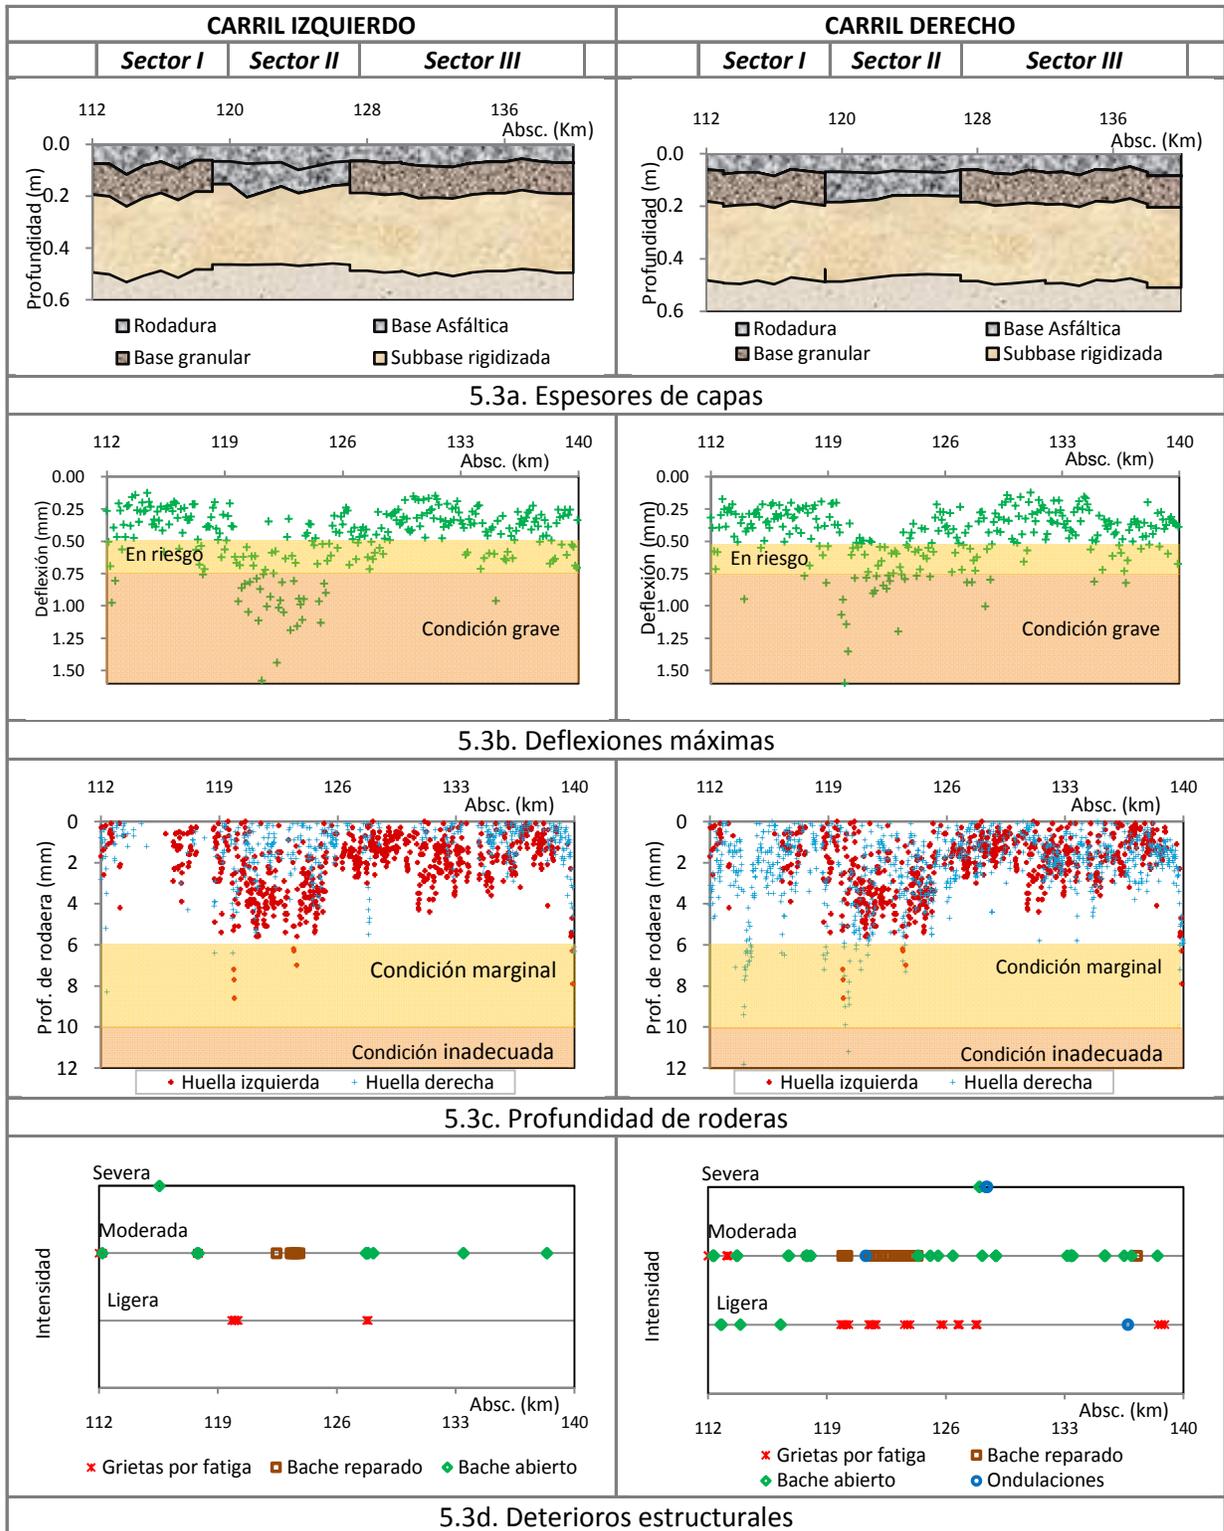
(M): Medida (C): Calculada (A): Asumida con base en la experiencia (N): Numérica (L): Lingüística

Las principales variables asociadas con las pruebas de deflexión utilizadas en este estudio se ilustran en la Figura 3.5; la carga aplicada varía en un rango de 4 a 7 ton y en cada prueba se utilizaron 7 sensores para medir las cuencas, localizados a 0.0 m, 0.3 m, 0.45 m, 0.6 m, 0.9 m, 1.2 m and 1.8 m de distancia desde el eje de carga.

5.2 Análisis preliminares

Con base en la información disponible, se elaboraron diversas gráficas para efectos de realizar un análisis inicial que permita caracterizar globalmente la vía en estudio, identificar las diferentes respuestas del pavimento y definir sectores preliminares. La Figura 5.3 ilustra la variación de los materiales y espesores de capa, las deflexiones máximas, profundidades de rodera y deterioro registrado en ambos carriles a lo largo del corredor.

En la Figura 5.3a se identifican tres sectores desde el punto de vista de los sistemas de pavimento presentes: **el sector I** comprendido entre el K112 y el K119.7; **el sector II** entre el K119.7 y el K127 y el **sector III** entre el K127 y el K140. El sector II exhibe una estructura tricapa donde la rigidez decrece con la profundidad, mientras los sectores I y III poseen una estructura de cuatro capas donde la base granular (ligeramente estabilizada con cemento en algunos tramos) posee menor rigidez que la capa de subbase rigidizada con cemento Portland sobre la cual se apoya. En la Tabla 5.2 se incluyen los espesores de capas en los dos sistemas estructurales identificados.



Fuente: Cálculos propios; datos de Orozco (2005)

Figura 5.3 Características medidas en el corredor analizado

Tabla 5.2 Espesores de capas del pavimento (m)

| Capa | Sistema tricapa | Sistema cuatro capas |
|--------------------------------|--|-------------------------|
| Asfáltica | Rodadura + Base asfáltica 0.15 – 0.20 | Rodadura 0.06 – 0.10 |
| Base granular* | 0.00 | 0.11 – 0.13 |
| Subbase rigidizada con cemento | 0.30 | |
| Capas inferiores | 3.00 | |

* Estabilizada localmente con cemento

Según se aprecia en la Figura 5.3b, el sector II registra las mayores deflexiones, lo cual puede estar asociado con el efecto combinado entre las diferencias de espesores, la presencia de una base asfáltica que hace parte de la capa superficial y la mayor concentración de deterioro estructural observada en Figura 5.3(c y d). En los sectores I y III, aparentemente las mayores deflexiones se encuentran asociadas con sectores donde predominan daños tipo baches abiertos con intensidad moderada a severa y mayores profundidades de roderas; posteriormente se verificará su relación con deficiencias en los parámetros de comportamiento.

Para tener una idea de la capacidad global, se calcularon los indicadores estructurales A, $A_{No.9}$, I_e , BLI, MLI, LLI, MRD, RD y F2, derivados de las cuencas de deflexión medidas a lo largo del corredor, según se describió en el numeral 3.2.4. A la luz de los criterios allí expuestos, se elaboró la Tabla 5.3 donde se presentan las proporciones de los registros que reflejan condiciones regular a mala (o en riesgo a grave). Según las proporciones de los diferentes indicadores, se obtiene un amplio espectro para caracterizar el comportamiento; las condiciones extremas estarían dadas por **A** que indica inexistencia de deficiencias graves y $A_{No.9}$ con pavimento débil en 60% del corredor.

Tabla 5.3 Distribución de datos que indican deficiencias estructurales (%)

| Sector | I | | | | II | | | | III | | | | Total corredor | |
|-------------|---------------------|--------------|---------------------|--------------|---------------------|--------------|---------------------|--------------|---------------------|--------------|---------------------|--------------|---------------------|--------------|
| | Izquierdo | | Derecho | | Izquierdo | | Derecho | | Izquierdo | | Derecho | | Ambos carriles | |
| Indicador | Regular o en riesgo | Grave o mala | Regular o en riesgo | Grave o mala | Regular o en riesgo | Grave o mala | Regular o en riesgo | Grave o mala | Regular o en riesgo | Grave o mala | Regular o en riesgo | Grave o mala | Regular o en riesgo | Grave o mala |
| $D_{máx}^1$ | 2 | 1 | 2 | 1 | 4 | 5 | 5 | 4 | 5 | 0 | 4 | 1 | 22 | 12 |
| $D_{máx}^2$ | | 1 | | 1 | | 5 | | 4 | | 1 | | 2 | | 14 |
| A | 1 | 0 | 1 | 0 | 7 | 0 | 5 | 0 | 1 | 0 | 2 | 0 | 17 | 0 |
| $A_{No.9}$ | | 5 | | 3 | | 12 | | 11 | | 13 | | 15 | | 60 |
| I_e | 1 | 0 | 1 | 0 | 5 | 2 | 4 | 1 | 1 | 0 | 2 | 0 | 14 | 3 |
| BLI | 3 | 0 | 1 | 0 | 6 | 4 | 8 | 2 | 6 | 0 | 7 | 1 | 31 | 7 |
| MLI | 3 | 0 | 3 | 0 | 5 | 3 | 4 | 1 | 4 | 0 | 5 | 0 | 24 | 4 |
| LLI | 5 | 0 | 4 | 0 | 6 | 4 | 7 | 2 | 7 | 0 | 8 | 0 | 37 | 6 |

 $D_{máx}^1$ (Horak y Emery) $D_{máx}^2$ (Zárate y Lucero; Gómez et al)

Fuente: cálculos propios

En la Figura 5.4 se ilustra la variación de estos indicadores, con lo cual se pueden identificar las zonas que tienen alguna deficiencia estructural.

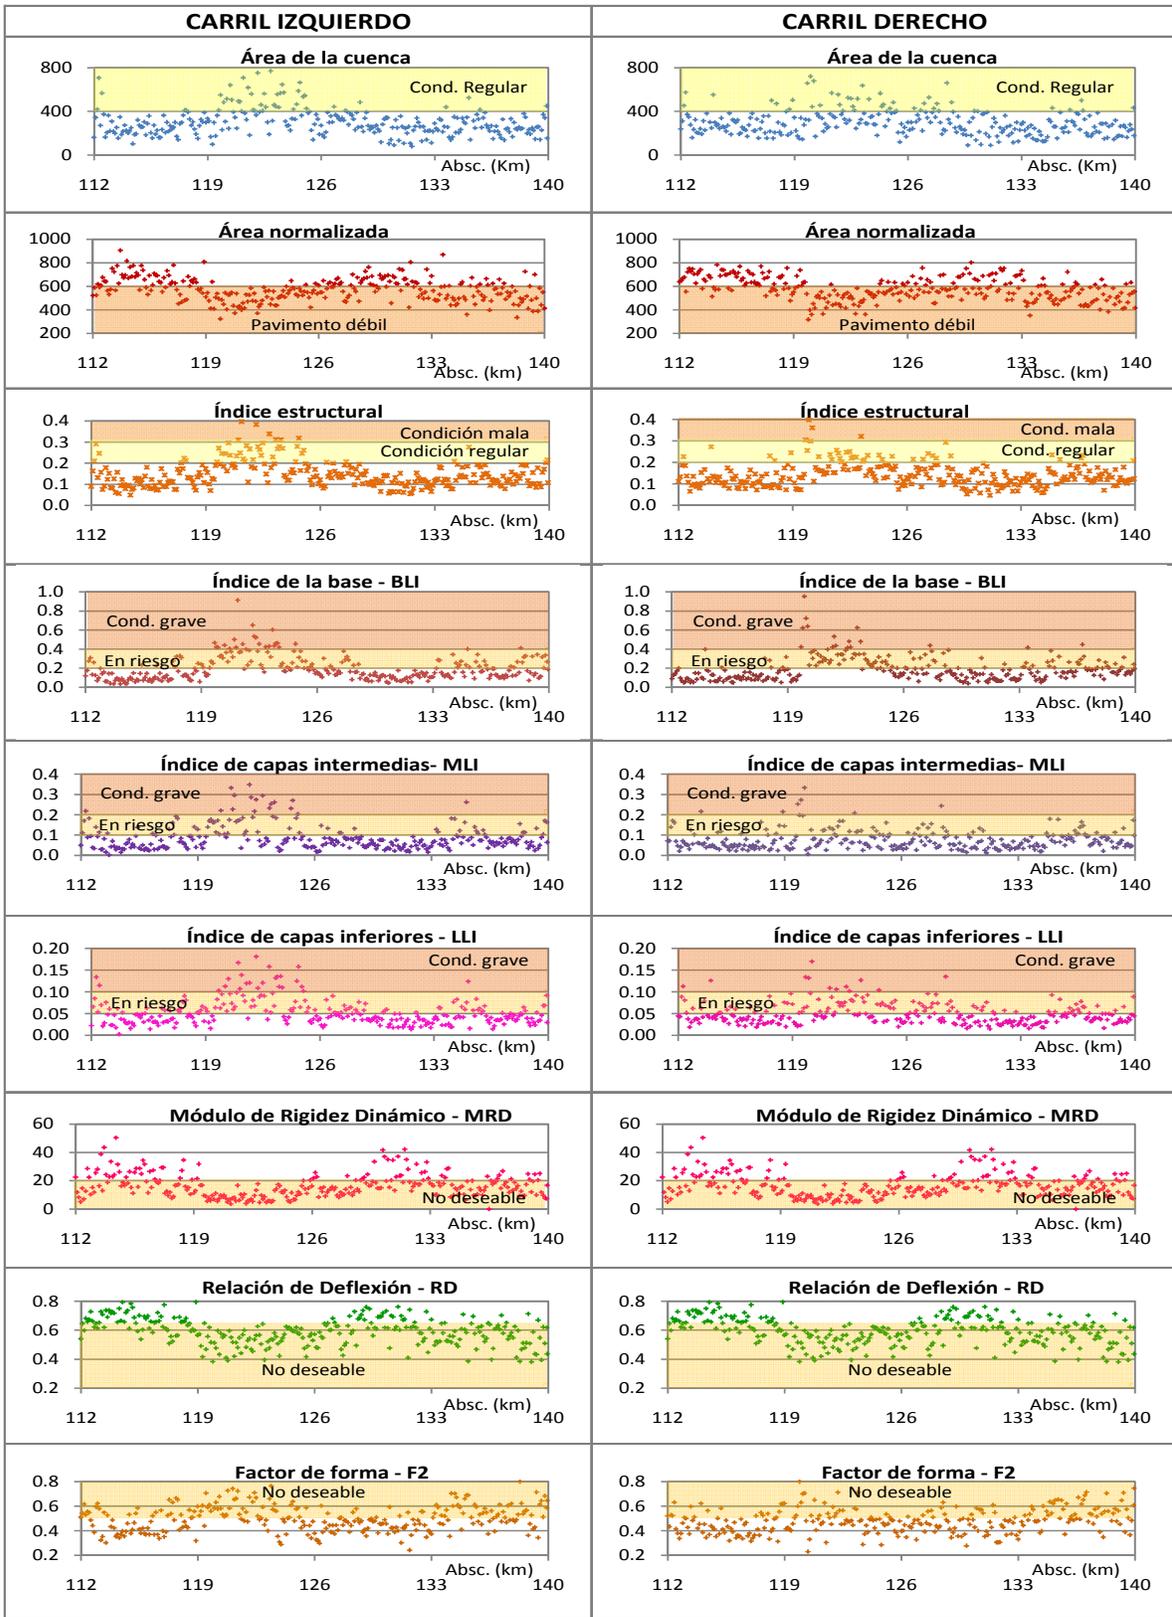


Figura 5.4 Indicadores estructurales deducidos de las cuencas de deflexión

Se aprecia que el sector II, donde existe estructura tricapa, presenta los indicadores de comportamiento más desfavorables en ambos carriles. A continuación se analizan en detalle todos los índices considerados, con el ánimo de identificar los más representativos del comportamiento del pavimento y sus capas de soporte.

Las mayores valores de deflexión máxima – **D_{máx}**, indican sitios con deficiencia global del pavimento; con ayuda de los índices BLI, MLI y LLI es posible identificar la capa o capas responsables de tal deficiencia, y por lo tanto la profundidad hasta la cual habría que intervenir. Aunque se observa que los sitios donde los cuatro indicadores reflejan condición grave generalmente coinciden con los sitios más afectados por deterioro, no necesariamente en todos esos casos se desarrolla algún tipo de daño. Esto es importante considerarlo a la hora de definir intervenciones pues no solamente se generan acciones para corregir el deterioro, sino también para controlarlos.

Por su parte, de acuerdo con el indicador **A** (área de las cuencas de deflexión), no existen condiciones graves de capacidad en el corredor y el 17% de los datos reflejan algunos sitios con condición regular (**A** entre 400 y 800 mm²); sin embargo, para esos mismos sitios los demás indicadores reflejan condiciones graves de rigidez en alguna o algunas capas y presencia de deterioro inadecuado; por esta razón, **A** no se considera en este estudio como un indicador significativo de cambios estructurales en el corredor.

En cuanto al área normalizada - **A_{No.9}**, se encontró que los valores menores de 600 mm coinciden con sitios donde los demás indicadores reflejan deficiencia global o en alguna de las capas de la estructura. Considerando los criterios planteados en la Tabla 3.4 y la Figura 3.8, respecto al **A_{No.9}** y su relación con **D_{máx}**, se elaboró Figura 5.5, donde se clasifica la suficiencia estructural del pavimento (capa asfáltica, base y subbase) y de las capas inferiores o subrasante.

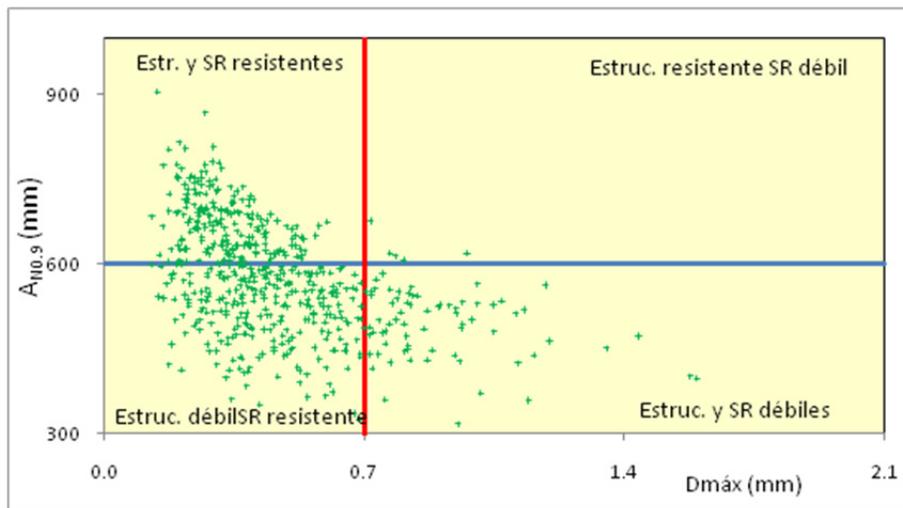


Figura 5.5 Clasificación de la capacidad de soporte en función de AN y D_{máx}

El 40% de los datos reflejan capacidad adecuada en la estructura y en las capas inferiores; el 11% de los datos indican deficiencia en ambos componentes ($D_{m\acute{a}x} \geq 0.7$ y $A_{N0.9} \leq 600$); el 1% se asocia con debilidad sólo en la subrasante. El 48% restante de las cuencas analizadas poseen valores críticos de $A_{N0.9}$ y $D_{m\acute{a}x}$ aceptables que en teoría, reflejaría debilidad atribuida sólo a las capas del pavimento. Sin embargo, revisando los indicadores BLI y MLI, se encontró que en la mitad de estos casos los índices no reflejan deficiencia en alguna de las capas mencionadas.

Se concluye que los criterios de evaluación establecidos a partir de la relación entre $A_{N0.9}$ y $D_{m\acute{a}x}$, resultan confiables para identificar los datos que reflejan resistencia global adecuada y debilidad atribuida únicamente a la subrasante. Para la base de datos analizada en este estudio, estos criterios no fueron suficientes para identificar claramente las capas donde se presenta buena parte de las deficiencias a lo largo del corredor. Así mismo, aunque el análisis basado en la Figura 5.5 permite observar la distribución de los datos y tener una idea global de la condición estructural, no es posible ubicar espacialmente dentro del corredor los sitios con problemas. Por último, según se mencionó anteriormente, $A_{N0.9}$ proporciona el escenario de evaluación más crítico entre todos los indicadores analizados, por lo que podría considerarse eventualmente en posteriores análisis como un índice de verificación.

De acuerdo con el Índice estructural - I_e , se obtiene uno de los escenarios más optimistas de la capacidad global de la estructura, pues sólo el 3% de los datos reflejan capacidad estructural global mala y 14% representan zonas de condición regular, en su mayoría concentrados en el sector II, donde existe estructura tricapa. Aunque el análisis conjunto con BLI, MLI y LLI indica que los sitios que poseen condición grave en todas las capas coinciden con mala condición ($I_e \geq 0.30$), también se identifican situaciones donde el pavimento exhibe deterioro inadecuado y los demás indicadores reflejan condiciones malas o de riesgo, no reflejadas en los valores de I_e .

El índice estructural evalúa solo la porción de la cuenca desde el eje de carga hasta la zona de inflexión (ver Figura 3.9 y Figura 3.10); por su relación directa con $D_{m\acute{a}x}$ existe una correlación casi perfecta entre estos dos indicadores, según se indica en la Figura 5.6. Por ello, I_e puede resultar redundante para ciertos análisis, aunque puede aportar criterios para la definición de acciones de mantenimiento, según se indicó en la Tabla 3.5.

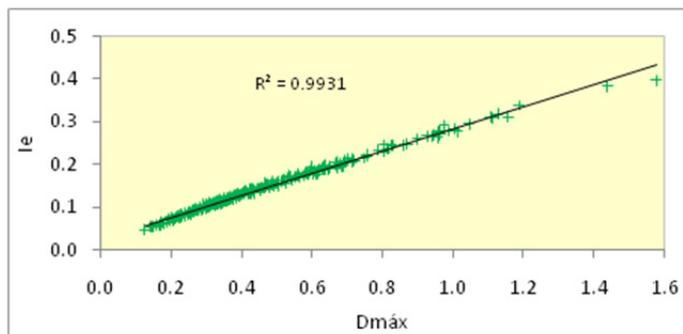


Figura 5.6 Relación entre los índices I_e y $D_{m\acute{a}x}$

Por su parte, los índices **BLI**, **MLI** y **LLI** correlacionan muy bien con $D_{m\acute{a}x}$, como se aprecia en la Figura 5.7, con la ventaja adicional de que permiten ubicar tanto los sectores con problemas, como los componentes de pavimento a los cuales se atribuyen las deficiencias con sus respectivos niveles de gravedad.

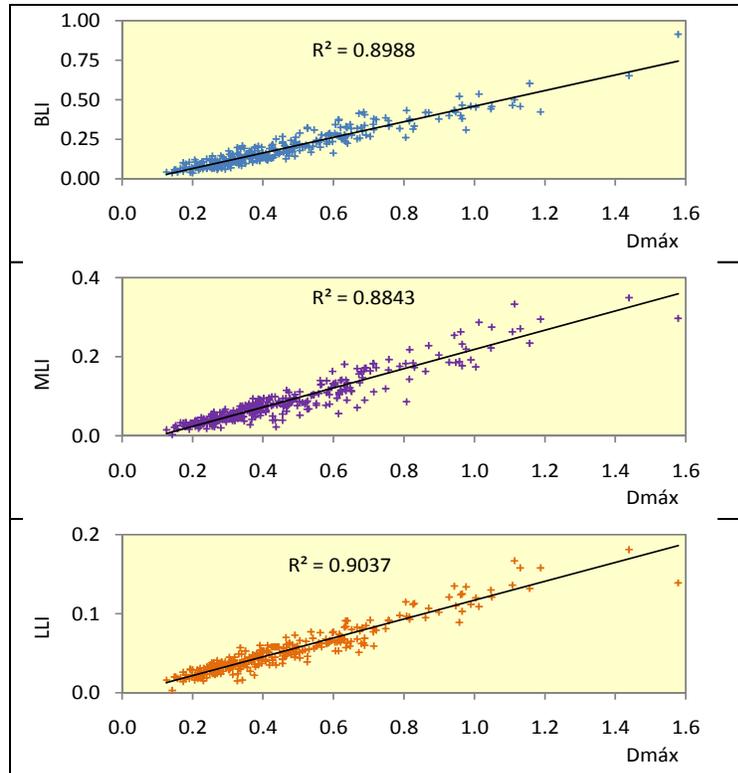


Figura 5.7 Relación entre índices de forma de las cuencas y $D_{m\acute{a}x}$

El módulo de rigidez dinámica **MRD** expresado como la relación entre el impulso de carga y $D_{m\acute{a}x}$, está condicionado a las variaciones de esta última, dado el estrecho rango en los niveles de carga aplicada en las pruebas de deflexión analizadas en este estudio; por tanto, MRD no aporta información adicional para caracterizar estructuralmente el corredor analizado. Esto mismo podría aplicarse al factor de forma **F2** y a la relación de deflexión **RD** los cuales evalúan zonas de la cuenca de deflexiones ya evaluadas por otros indicadores.

Vale la pena resaltar que para pavimentos con diferentes estructuras y respuestas de deflexión diversas, es factible obtener valores similares en los diferentes indicadores deducidos a partir de las cuencas. En la Figura 5.8 se ilustran algunos ejemplos de estas situaciones detectadas en el corredor estudiado. De esta gráfica se puede concluir que no resulta suficiente valorar la capacidad estructural con base en cada indicador individual, sino que éstos deben integrarse con los demás elementos de la evaluación para lograr una descripción más completa de la condición del pavimento.

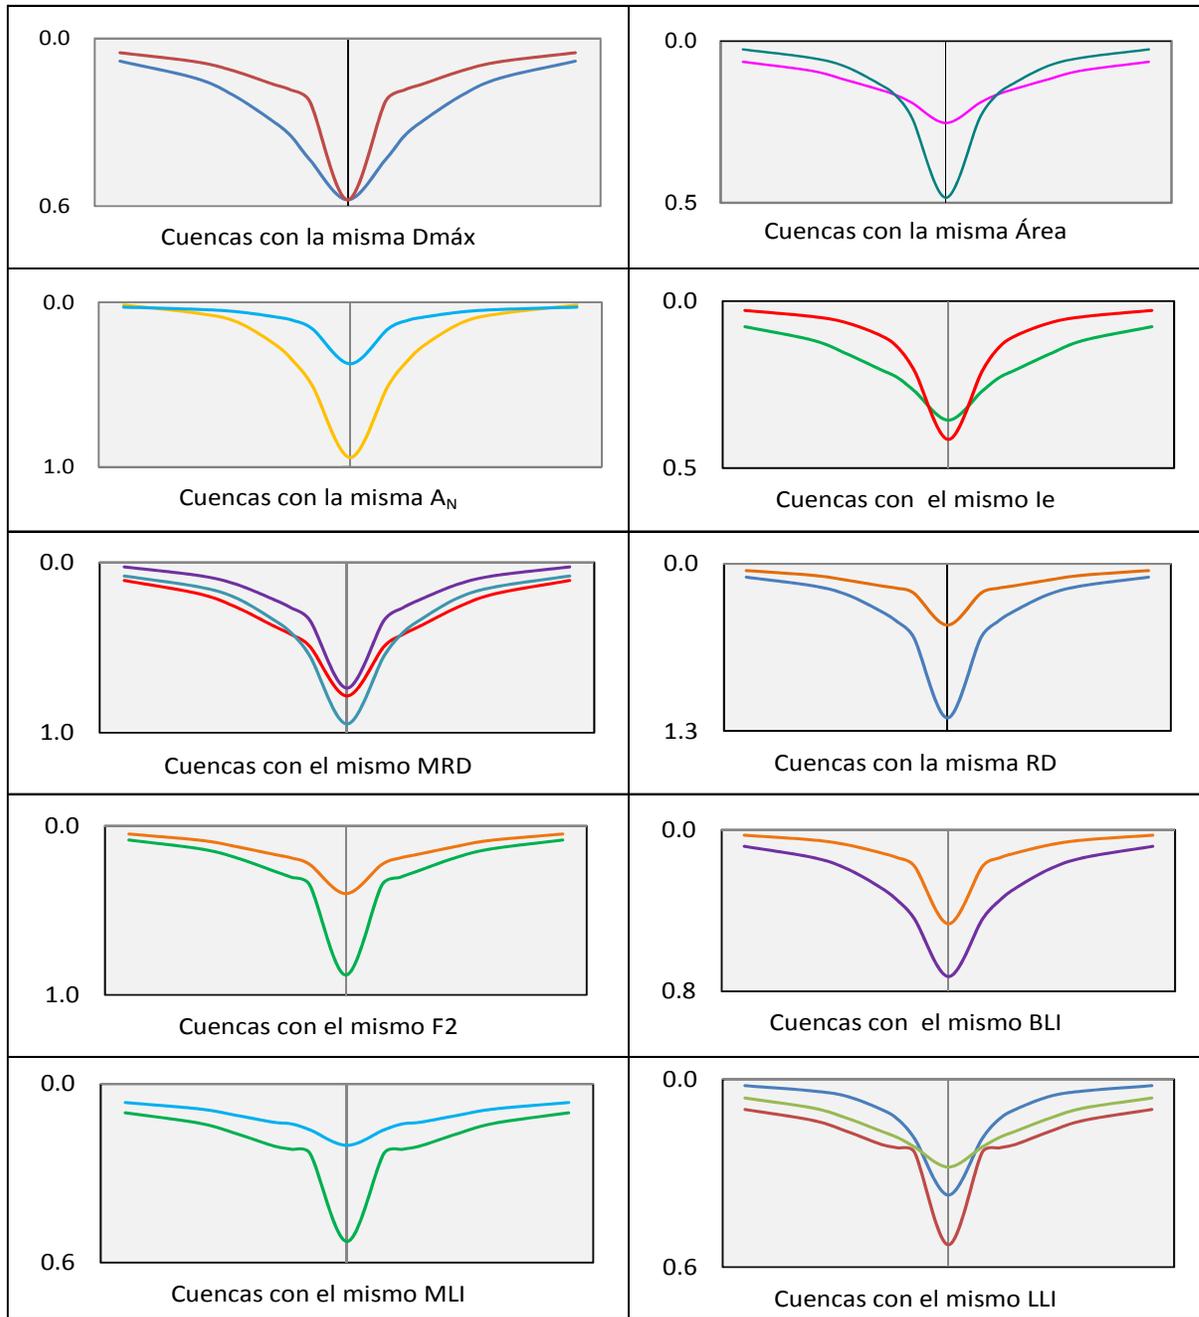


Figura 5.8 Respuestas de deflexión diferentes con indicadores similares

Como producto del análisis anterior, los indicadores **$D_{máx}$** , **BLI**, **MLI** y **LLI** se identifican como representativos para evaluar la capacidad estructural del pavimento considerado en este estudio. El índice estructural – **le** , se utiliza para ayudar a definir sectores homogéneos preliminares y soluciones de intervención. Los demás indicadores, se consideran de verificación en la medida que guarden relación con los parámetros mecánicos que se determinan posteriormente.

En la Tabla 5.4 y en la Figura 5.9 se presentan algunos ejemplos de cuencas de deflexión, en los cuales los indicadores seleccionados aportan criterios que se complementan para caracterizar el comportamiento a partir de la forma de la cuenca.

Tabla 5.4 Caracterización del pavimento según forma de la cuenca

| Abscisa | Estructura | D _{máx} (mm) | BLI (mm) | MLI (mm) | LLI (mm) | Pavimento |
|---------|------------|-----------------------|--------------|--------------|--------------|---|
| K115.7 | 4 capas | 0.206 | 0.052 | 0.026 | 0.023 | Alta rigidez global |
| K128.4 | | 1.004 | 0.360 | 0.244 | 0.135 | Debilidad atribuida a la subbase y capas inferiores |
| K120.0 | 3 capas | 1.596 | 0.953 | 0.273 | 0.132 | Debilidad total de la estructura |
| K123.9 | | 0.476 | 0.248 | 0.058 | 0.043 | Buenas condiciones de rigidez |

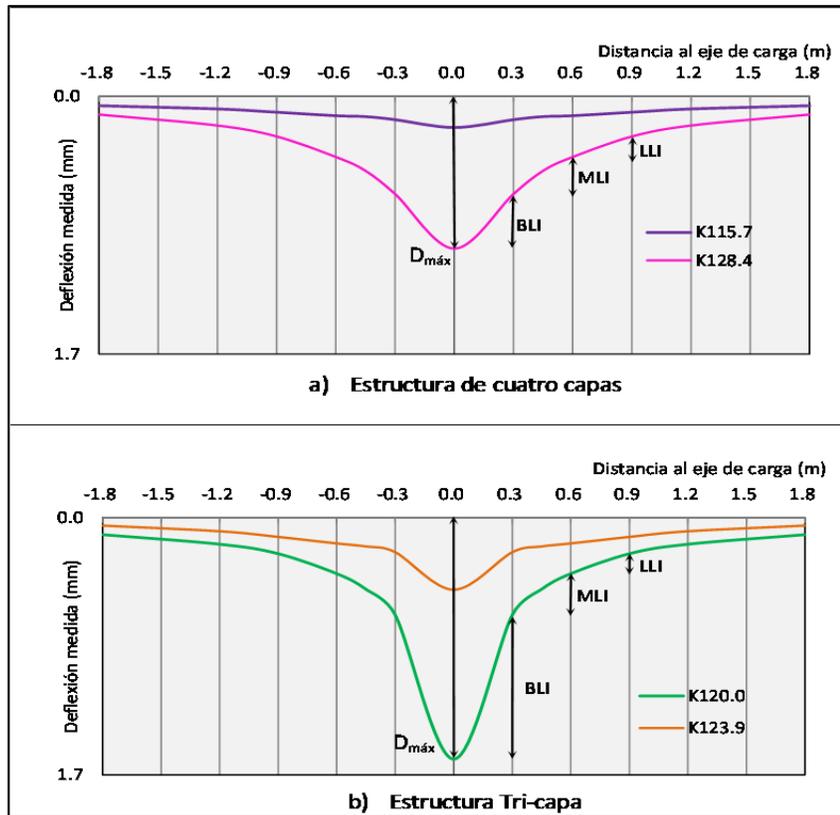


Figura 5.9 Indicadores de rigidez y forma de la cuenca

Como parte final de los análisis preliminares y para corroborar los tres sectores identificados por los cambios de estructura, se aplicó el método de las diferencias acumuladas, descrito en el numeral 3.4, a los valores de D_{máx} y de *le* registrados a lo largo del corredor. En la Figura 5.10 se ilustran los cambios significativos en la pendiente de las curvas obtenidas, los cuales indican fronteras entre sectores con diferente respuesta.

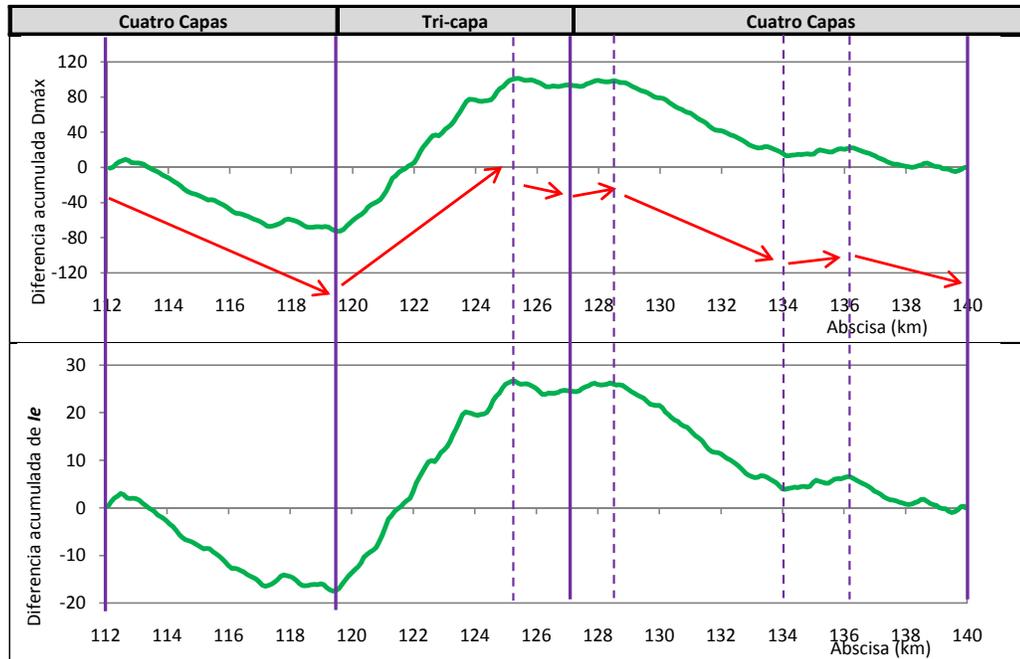


Figura 5.10 Sectores por diferencias acumuladas de I_e y $D_{máx}$

Mediante esta metodología, se identifica claramente que los sistemas de pavimento presentes en el corredor (cuatro y tres capas) marcan las fronteras estructurales básicas de los tres sectores definidos previamente por Orozco (2005). Adicionalmente, en los tramos intermedio y final se generan subsectores en virtud de las respuestas de deflexión, para conformar siete sectores, cuya pertinencia se evaluará más adelante cuando se definan las condiciones estructurales derivadas de las modelaciones propuestas en este estudio.

5.3 Identificación de parámetros mecánicos mediante RNAs

En esta etapa se propone la utilización de métodos adaptativos basados en RNAs para estimar parámetros asociados con la resistencia y rigidez de las capas que componen el pavimento. En particular, para estimar los módulos de capa a partir de los datos de deflexiones medidas en campo, se sigue un proceso conformado por cinco pasos:

1. Diseño del modelo neuronal óptimo
2. Verificación de la calidad de las predicciones –ajuste de deflexiones medidas y calculadas
3. Evaluación de la capacidad de generalización del modelo propuesto
4. Incidencia de la relación de Poisson en la estimación de módulos
5. Análisis de resultados: coherencia entre las estimaciones y las condiciones reales que exhibe el pavimento; sensibilidad de las variables.

En los dos primeros pasos, se utiliza la información disponible de auscultación en el carril derecho del corredor y en los tres pasos restantes se emplean los datos del carril izquierdo. A continuación se describen en detalle cada uno de los cinco pasos mencionados.

5.3.1 Diseño del modelo neuronal para estimar módulos de capa

La primera tarea para diseñar una RNA capaz de predecir módulos de capa de un pavimento, consiste en identificar las variables sensibles en los conjuntos de datos de entrada y de salida.

Inicialmente se consideraron 23 variables de entrada asociadas con las pruebas de deflexión y la estructura del pavimento (ver Tabla 5.1). Teniendo en cuenta que la posición de los siete sensores permanece constante en todas las pruebas de deflexión, las variables de entrada se reducen a 16: un nivel de carga (Q), siete deflexiones superficiales medidas en cada sensor y en cada prueba ($D_1, D_2, D_3, D_4, D_5, D_6, D_7$), cuatro espesores de capas (h_1, h_2, h_3, h_4) conformadas por cuatro tipos de materiales diferentes.

Para efectos de caracterizar el tipo de material de cada capa, se optó por asumir valores de la relación de Poisson ($\nu_1, \nu_2, \nu_3, \nu_4$) puesto que sus intervalos de variación son bastante estrechos para cada capa. En principio, se utilizaron valores típicos constantes de 0.3, 0.4, 0.35 y 0.45 respectivamente para capa asfáltica, base granular, subbase rigidizada y capas inferiores, con el único fin de representar numéricamente el tipo de material.

En investigaciones previas se menciona el efecto poco significativo que tiene el asumir valores constantes de la relación de Poisson sobre la estimación de módulos de capa (Uzan, 1994; Ullidtz, 2000; Huang, 2003; ARA Inc. & ERES 2004). Para evaluar el verdadero impacto en las estimaciones, en este estudio se incluye un análisis de sensibilidad adicional, considerando valores variables de la relación de Poisson, cuyos resultados se presentan en el numeral 5.3.4.

En cuanto al conjunto de datos de salida, como una primera aproximación de los módulos esperados E_{ES} , se utilizaron los valores estimados por Orozco (2005) mediante teoría elástica multicapa a partir de la misma base de datos usada en este estudio.

Para esta investigación se utiliza la configuración de modelo neuronal de tres capas ilustrada en la Figura 5.11, teniendo en cuenta las recomendaciones de estudios previos (Goktepe *et al*, 2006 y Sharma y Das 2008), donde las RNAs con una capa oculta han mostrado mejor desempeño que las de dos capas ocultas para la estimación de módulos. Mediante ensayo y error, se encontró que cuatro neuronas en la capa oculta resultan suficientes para proporcionar buenos resultados en muy poco tiempo.

De un total de 278 cuencas de deflexión medidas en el carril derecho de la vía analizada, se seleccionaron 200 para la fase de **entrenamiento** de la red neuronal, cuya aproximación se evaluó utilizando las 78 cuencas de deflexión restantes para la fase de **prueba**.

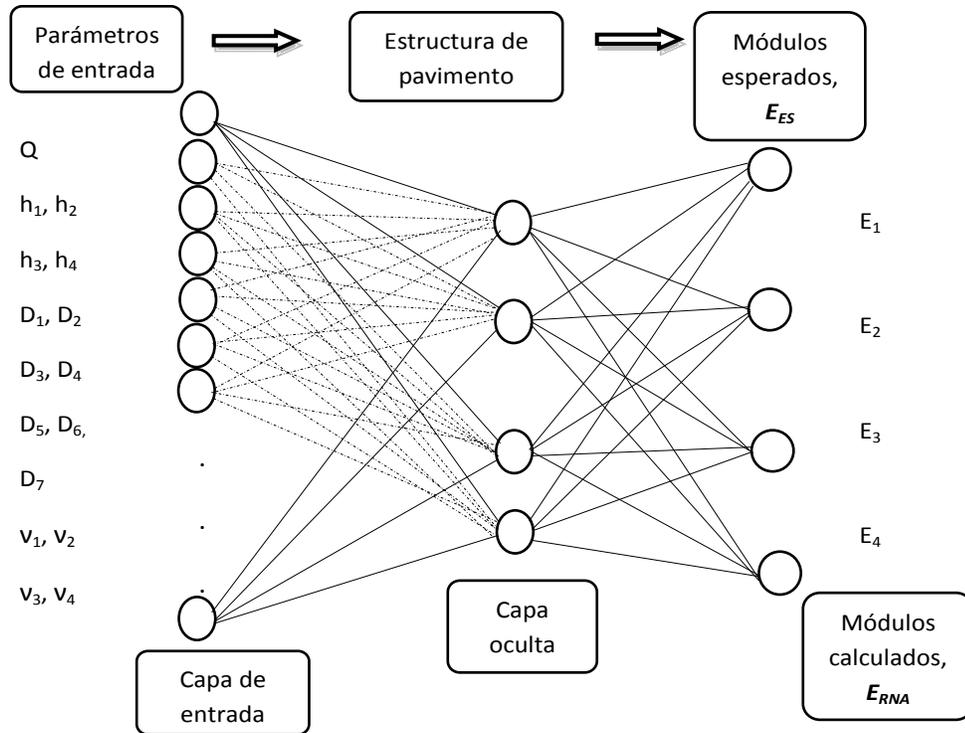


Figura 5.11 Configuración del modelo neuronal propuesto

La red mostrada en la Figura 5.11 se diseñó de manera genérica para evaluar estructuras de pavimento con cuatro capas. La simulación de la estructura tricapa en la zona intermedia del corredor, donde no existe base granular, se realizó asignando valores nulos a los espesores, relación de Poisson y módulos esperados para dicha capa. Mediante este simple artificio, se pretende aportar una modelación robusta, capaz de modelar simultáneamente el comportamiento en todos los sitios del corredor.

Para diseñar el modelo neuronal óptimo, definido por la mejor arquitectura posible junto con la regla de aprendizaje más adecuada y demás elementos propios de las RNAs, se consideraron 18 combinaciones incluidas en la Tabla 5.5, con opciones de aprendizaje supervisado y reforzado.

Tabla 5.5 Opciones consideradas en el análisis de sensibilidad

| Arquitectura | Algoritmo de aprendizaje | |
|---------------------------------|--------------------------|--|
| Multicapa de propagación normal | Supervisado | Retro propagación |
| | | Propagación Rápida |
| Jacob Mejorada | | |
| Multicapa de propagación total | | Enfriamiento simulado |
| | | Optimización aleatoria de Solis & Wets |
| | | Método de Powell |
| Jordan Recurrente | Reforzado | |

El análisis de sensibilidad realizado permitió identificar además, que mediante la utilización de los siguientes elementos se logran los mejores desempeños de la red: como método de pre-procesamiento, la desviación estándar media y como funciones de entrada y de transferencia, el producto punto y la función sigmoidea respectivamente.

La aproximación entre los módulos teóricos esperados E_{ES} y los valores calculados por la red E_{RNA} , se evaluó mediante el error medio absoluto, EMA, como criterio de convergencia. Adicionalmente, durante el entrenamiento se verificó que la tendencia del error fuera decreciente después de cada 500 iteraciones; en caso contrario, los valores E_{ES} se actualizaron para las siguientes iteraciones, asumiendo como nuevos valores aquellos calculados por la red E_{RNA} en la última iteración, según se ilustra en el diagrama de la Figura 5.12; con ello se mejora ampliamente la posibilidad de satisfacer el criterio de convergencia adoptado.

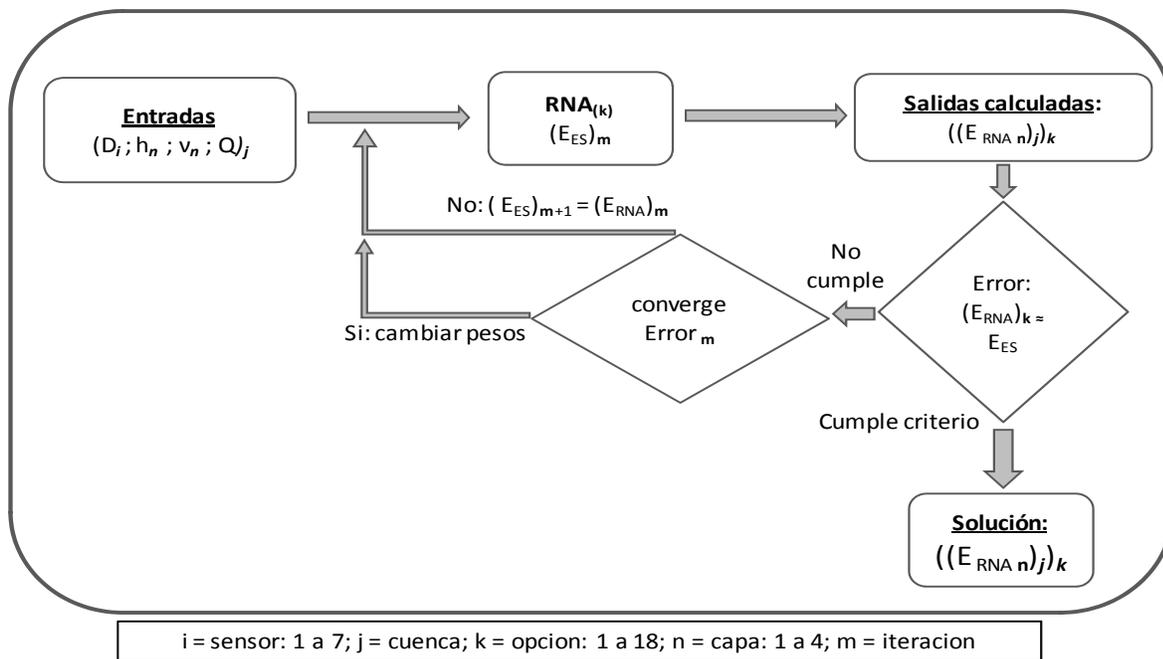


Figura 5.12 Proceso de cálculo de módulos mediante RNA

Como resultado de este proceso se obtienen 18 posibles soluciones o conjuntos de módulos de capa para cada punto evaluado sobre la vía, conforme a lo discutido en Mehta y Roque (2003): diferentes combinaciones de módulos de capa pueden dar lugar a errores similares. En consecuencia, para ayudar a seleccionar el conjunto más adecuado de módulos entre todas las opciones consideradas, se llevó a cabo una evaluación de las cuencas de deflexión.

5.3.2 Evaluación del ajuste de cuencas de deflexión

Teniendo en cuenta que la respuesta de deflexiones medidas sobre el pavimento es función de la rigidez, caracterizada por los módulos de capa, la evaluación de deflexiones se realiza con el

propósito de determinar cuál de los conjuntos de módulos calculados tiene la capacidad de reproducir de manera más cercana las cuencas medidas en campo.

Para identificar la mejor opción, se aplica nuevamente la modelación neuronal con aprendizaje supervisado, donde los módulos E_{RNA} obtenidos con la red mostrada en la Figura 5.11 se utilizan como entradas y las cuencas de deflexión medidas - D_{MED} como salidas esperadas.

La red calcula unas nuevas deflexiones D_{RNA} , cuya similitud con D_{MED} se evalúa con base en el criterio de error y de similitud con la coincidencia perfecta. Esta coincidencia se define como aquella en la cual existe regresión lineal entre D_{RNA} y D_{MED} , con un coeficiente de determinación (r^2) y una pendiente de la línea tendencia (b) iguales a uno y con un valor del intercepto (a) igual a cero. La opción que produzca el mínimo error junto con mejores indicadores del análisis de regresión, se selecciona como óptima. En la Figura 5.13 se muestra el proceso descrito.

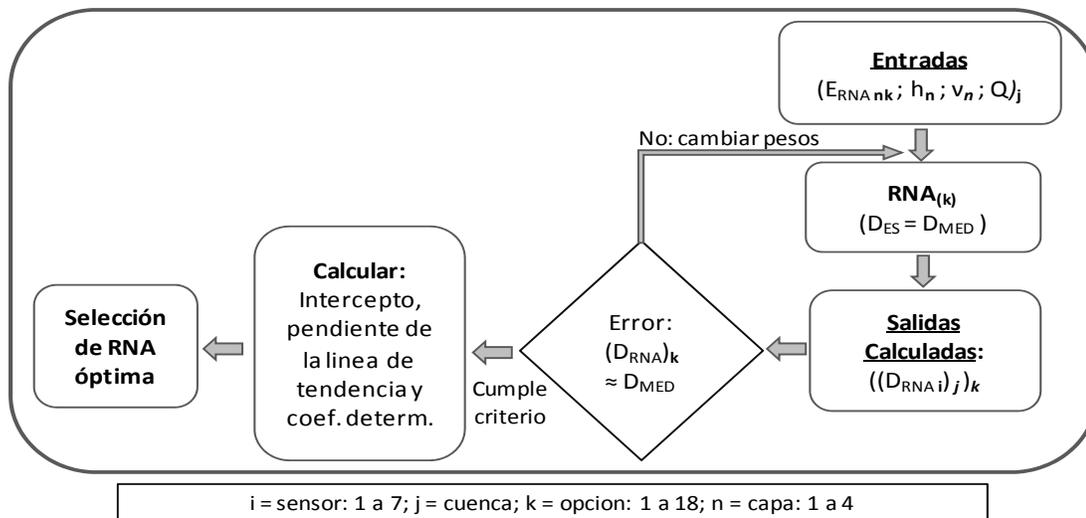


Figura 5.13 Proceso de evaluación del ajuste de deflexiones

Como producto de la aplicación de este proceso a las 18 combinaciones consideradas, se obtuvieron las deflexiones calculadas, las cuales se correlacionaron linealmente con las medidas en campo para obtener los indicadores mostrados en la Tabla 5.6. Se incluyen los valores obtenidos para los conjuntos de datos de entrenamiento y de prueba en cuanto al intercepto, la pendiente y el coeficiente de correlación de la línea de tendencia. Adicionalmente, se presentan los indicadores de desempeño de la red asociados con el error, el tiempo de procesamiento y la cantidad de iteraciones necesarias para lograr la convergencia.

Evaluando los resultados del conjunto de prueba, se puede apreciar que diez de las opciones muestran buenos niveles de aproximación, al menos en dos parámetros, y constituyen excelentes combinaciones que pueden usarse para determinar los módulos de capa mediante análisis con redes neuronales.

Tabla 5.6 Resumen de resultados del ajuste de deflexiones – carril derecho

| Arquitectura | Regla de aprendizaje | Entrenamiento | | | Prueba | | | Error (%) | Iterac. | Tiempo (min) |
|------------------------------|----------------------|---------------|-------|----------------|--------|-------|----------------|-----------|---------|--------------|
| | | a | b | r ² | a | b | r ² | | | |
| Multicapa propagación normal | Prop. rápida | 0.008 | 0.961 | 0.961 | 0.001 | 0.984 | 0.942 | 2.0 | 485 | 1.0 |
| | Retro propag | 0.008 | 0.963 | 0.965 | 0.026 | 1.263 | 0.856 | 2.0 | 909 | 1.5 |
| | Jacob mej. | 0.012 | 0.942 | 0.943 | 0.003 | 1.063 | 0.932 | 2.0 | 529 | 1.5 |
| Multicapa propagación total | Prop. rápida | 0.009 | 0.960 | 0.958 | 0.002 | 0.960 | 0.934 | 2.0 | 475 | 2.0 |
| | Retro propag | 0.009 | 0.958 | 0.959 | 0.019 | 0.915 | 0.930 | 2.0 | 192 | 0.5 |
| | Jacob mej. | 0.008 | 0.962 | 0.962 | 0.008 | 0.936 | 0.897 | 2.2 | 871 | 1.3 |
| Jordan Recurrente | Prop. rápida | 0.009 | 0.955 | 0.947 | 0.013 | 0.957 | 0.940 | 3.2 | 176 | 0.5 |
| | Retro propag | 0.010 | 0.948 | 0.948 | 0.004 | 1.008 | 0.941 | 3.3 | 704 | 1.0 |
| | Jacob mej. | 0.010 | 0.950 | 0.953 | 0.001 | 1.019 | 0.941 | 3.3 | 176 | 0.2 |
| Multicapa propagación normal | Enfr. Simul. | 0.007 | 0.963 | 0.965 | 0.024 | 0.697 | 0.526 | 3.0 | 2000 | 6.0 |
| | Solis & Wets | 0.022 | 0.894 | 0.903 | 0.070 | 0.851 | 0.117 | 5.0 | 375 | 0.5 |
| | Powell | 0.006 | 0.972 | 0.976 | 0.067 | 1.298 | 0.632 | 2.5 | 1000 | 3.0 |
| Multicapa propagación total | Enfr. Simul. | 0.004 | 0.979 | 0.984 | 0.009 | 0.969 | 0.983 | 2.0 | 1056 | 1.5 |
| | Solis & Wets | 0.005 | 0.979 | 0.985 | 0.008 | 0.963 | 0.980 | 2.0 | 438 | 0.5 |
| | Powell | 0.014 | 0.932 | 0.939 | 0.009 | 0.972 | 0.951 | 3.9 | 1140 | 1.5 |
| Jordan Recurrente | Enfr. Simul. | 0.002 | 0.977 | 0.967 | 0.006 | 0.978 | 0.980 | 2.6 | 1173 | 2.0 |
| | Solis & Wets | 0.040 | 0.785 | 0.787 | 0.082 | 0.363 | 0.272 | 7.1 | 394 | 0.5 |
| | Powell | 0.008 | 0.959 | 0.960 | 0.138 | 2.831 | 0.370 | 3.0 | 1200 | 2.0 |

La RNA con arquitectura multicapa de propagación total hacia adelante con algoritmo de enfriamiento simulado produce el mayor coeficiente de determinación r^2 , el cual ha resultado concluyente en estudios previos para evaluar la calidad de los ajustes. Sin embargo, r^2 sólo permite juzgar el grado de correlación entre las deflexiones medidas y las calculadas, pero no necesariamente la similitud o igualdad entre ellas; para ello es necesario involucrar otros componentes de los análisis de regresión, como son la pendiente y el intercepto de la línea de tendencia al correlacionar las dos variables.

En esta investigación se seleccionó como óptima - RNA_{óp}, la red con arquitectura multicapa de propagación normal y algoritmo de propagación rápida, puesto que con los módulos estimados en esta opción arrojan deflexiones que satisfacen simultáneamente los criterios de error, de correlación y en especial la igualdad con los valores medidos, evaluada mediante la pendiente de la línea de tendencia y el intercepto, según se muestra en la Figura 5.14.

Mediante la opción seleccionada, se logró la convergencia a 2% de error medio absoluto después de 485 iteraciones en un minuto, tal como se muestra en la Figura 5.15, lo cual indica no sólo la precisión sino también la eficiencia de cómputo del modelo neuronal.

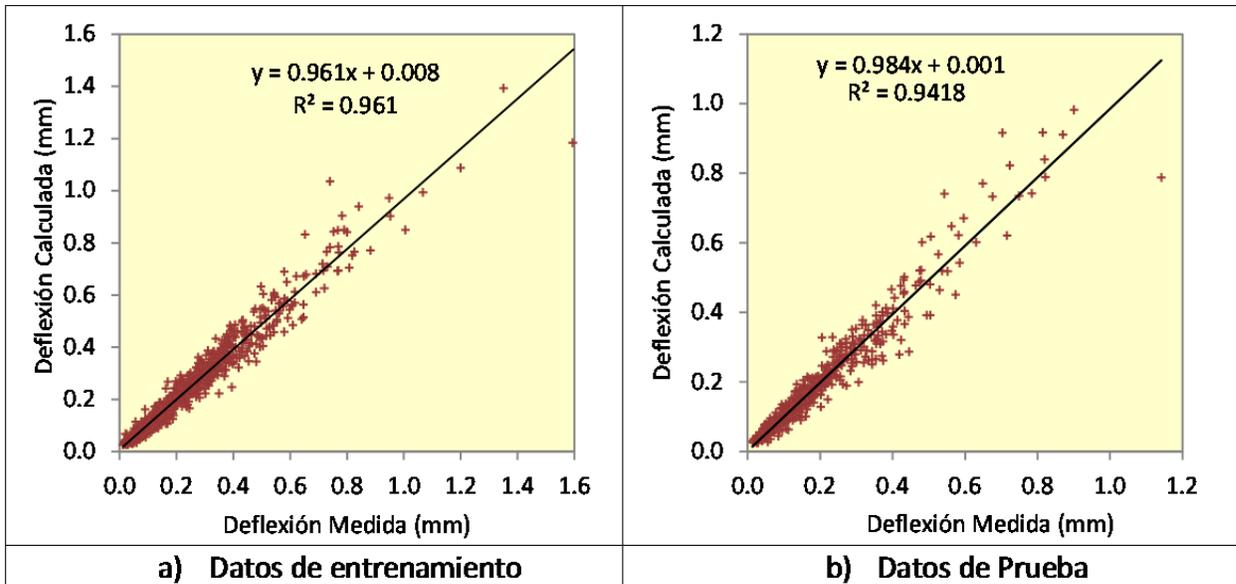


Figura 5.14 Deflexiones medidas y calculadas – carril derecho

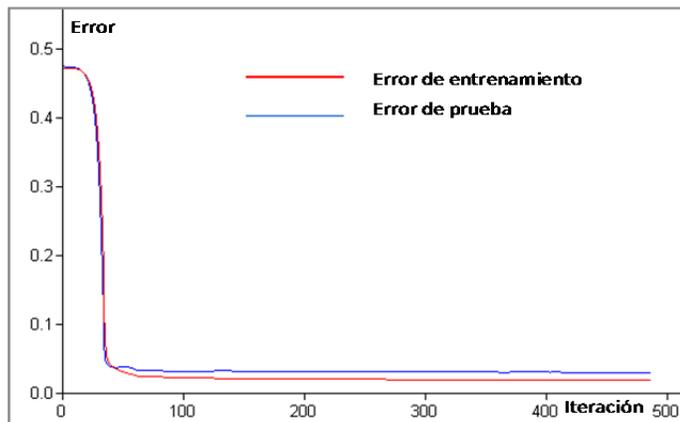


Figura 5.15 Tendencia del error durante el entrenamiento y prueba

En la Tabla 5.7 se presentan los módulos obtenidos mediante la $E_{RNAóp}$ para cada capa del pavimento en el carril derecho, así como los valores teóricos esperados E_{ES} utilizados como primera aproximación para el entrenamiento.

Tabla 5.7 Módulos estimados y esperados – carril derecho

| Capas | $E_{RNAóp}$ (Kg/cm ²) | E_{ES} (Kg/cm ²) |
|--------------------|-----------------------------------|--------------------------------|
| Asfálticas | 10700-82200 | 3500 - 84300 |
| Base Granular | 880 - 6200 | 500 - 6300 |
| Subbase rigidizada | 1950 - 8200 | 300 - 8000 |
| Inferiores | 790 - 3300 | 200 - 5000 |

Se puede apreciar que para todas las capas, la modelación neuronal proporcionó valores de módulos dentro de intervalos más estrechos o menos dispersos que aquellos utilizados como esperados en el entrenamiento.

Vale la pena señalar que los resultados anteriores resultan concluyentes para la etapa de diseño de la red, utilizando el conjunto de datos registrado en el carril derecho del corredor analizado. En los párrafos siguientes se evalúa la capacidad de la RNA_{óp} para pronosticar resultados razonables sobre un conjunto de datos diferente a los utilizados para diseñar la red.

5.3.3 Capacidad de generalización de la RNA_{óp}

La capacidad de generalización de la red diseñada, se evalúa calculando los módulos de capa a partir de la base de datos disponible para el carril izquierdo de la vía analizada. Los nuevos valores de espesores de capa, carga aplicada y cuencas de deflexión medidas en el carril izquierdo se introdujeron en la RNA_{óp} como variables de entrada en el conjunto de datos de prueba y se calcularon los módulos de cada capa para estas nuevas condiciones, ya sin necesidad de introducir los módulos deseados en las salidas.

Los módulos estimados, se utilizaron para verificar la similitud entre las cuencas de deflexión medidas y calculadas en el carril izquierdo, siguiendo un proceso similar al descrito anteriormente, con lo cual se obtuvieron los resultados mostrados en la Figura 5.16a.

Los niveles de aproximación de los pronósticos resultan satisfactorios, lo cual refleja la buena capacidad de la red para representar patrones diferentes a los utilizados para diseñar la red, aunque se haya asumido la hipótesis simplificadora de relaciones de Poisson constantes para cada capa. A continuación se realiza un análisis adicional, para verificar la posibilidad de mejorar aún más la calidad de las estimaciones.

5.3.4 Influencia de la Relación de Poisson

En este paso se integró un análisis de sensibilidad adicional para valorar el impacto que tiene en los resultados, el considerar relaciones de Poisson variables para cada una de las capas del pavimento. Para esos fines, se optó por estimar las relaciones de Poisson utilizando nuevamente el aprendizaje supervisado con RNAs.

Se seleccionaron 12 variables de entrada a la red, conformadas por la carga aplicada, las siete deflexiones medidas y las profundidades a las cuales se encuentran las cuatro capas del pavimento; se obtuvo entonces, una configuración de red muy similar a la mostrada en la Figura 5.11, con 12 neuronas de entrada, cuatro neuronas ocultas y cuatro neuronas de salida.

El conjunto de entrenamiento se conformó nuevamente con los datos del carril derecho y el de prueba con los del izquierdo. Después de unos cuantos segundos, se obtuvieron los valores de relaciones de Poisson para cada capa en los sitios evaluados; en la Tabla 5.8 se presentan los valores calculados por la red y los utilizados para el entrenamiento (esperados).

Tabla 5.8 Relaciones de Poisson estimadas con RNAs

| Capa | ν_{RNA} | ν_{ES} |
|--------------------|-------------|------------|
| Asfáltica | 0.24 – 0.35 | 0.3 |
| Base Granular | 0.31 – 0.42 | 0.4 |
| Subbase rigidizada | 0.29 – 0.40 | 0.35 |
| Inferiores | 0.41 – 0.48 | 0.45 |

Con las relaciones de Poisson obtenidas, se repitió todo el proceso para estimar otro conjunto de módulos de capa en el carril izquierdo y la correspondiente verificación de deflexiones; las nuevas estimaciones se compararon con aquellas obtenidas bajo condiciones de relaciones de Poisson constantes. En la Figura 5.16 se muestran los resultados obtenidos en la evaluación de deflexiones medidas y calculadas con los dos conjuntos de módulos.

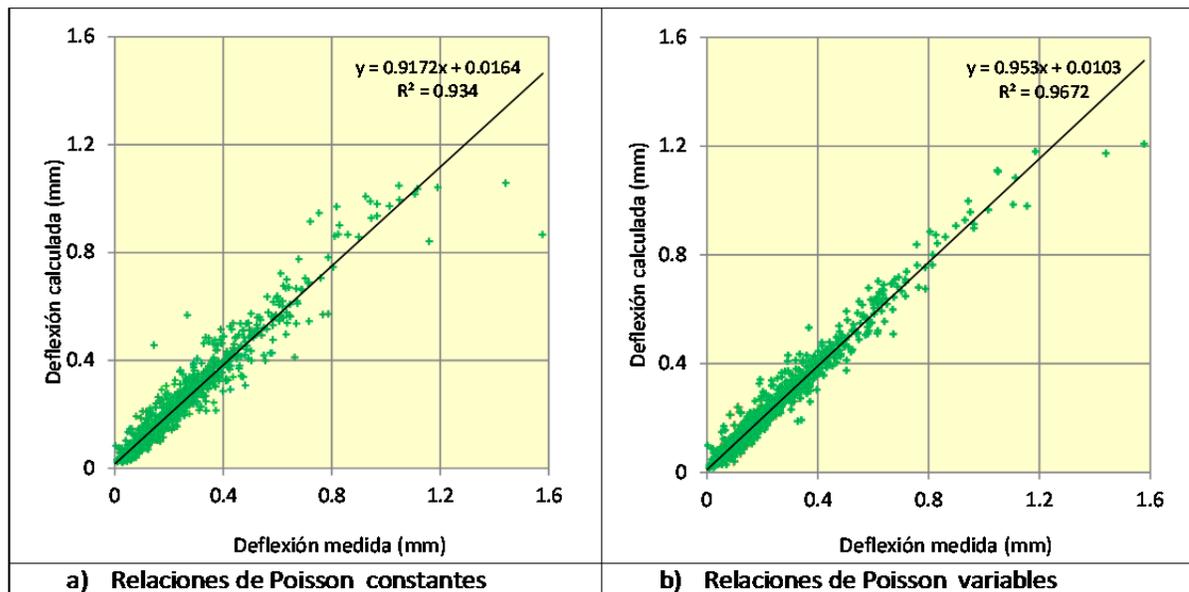


Figura 5.16 Verificación del ajuste de deflexiones - carril izquierdo

Para ambos casos se observan muy buenos ajustes, lo cual permiten evaluar no sólo la calidad de los módulos estimados sino también la capacidad de la red neuronal para reproducir la respuesta del pavimento ante pruebas no destructivas de deflexión. Bajo estas nuevas condiciones, el tiempo para lograr la convergencia se redujo a 30 segundos y 256 iteraciones.

Aunque los índices de regresión muestran una mejoría que a simple vista podría catalogarse como leve, es evidente que cuando se consideran relaciones de Poisson variables, se obtienen estimaciones menos dispersas respecto a las mediciones, en especial para los más altos niveles de deflexión. Por tal motivo, para los análisis posteriores que se realizan en esta investigación, se adoptan los módulos estimados bajo esta última consideración.

El análisis de los resultados obtenidos, permite reflexionar acerca de la conveniencia de asumir hipótesis preconcebidas respecto a la influencia que tiene la relación de Poisson en las estimaciones de los módulos de capa. En efecto, si se pretende simular de manera más apropiada el fenómeno físico real del pavimento, resulta muy conveniente eliminar la incertidumbre asociada con tales suposiciones; es ese sentido, las RNAs constituyen una opción muy rápida que aporta mayor precisión a las estimaciones finales de los módulos de capa.

Como producto final de esta etapa, en la Figura 5.17 se presentan los módulos de capa estimados a lo largo del carril izquierdo y su relación con los referentes incluidos en la Tabla 3.1, en cuanto a los valores típicos sugeridos por la ASTM y los reportados en el programa NCHRP.

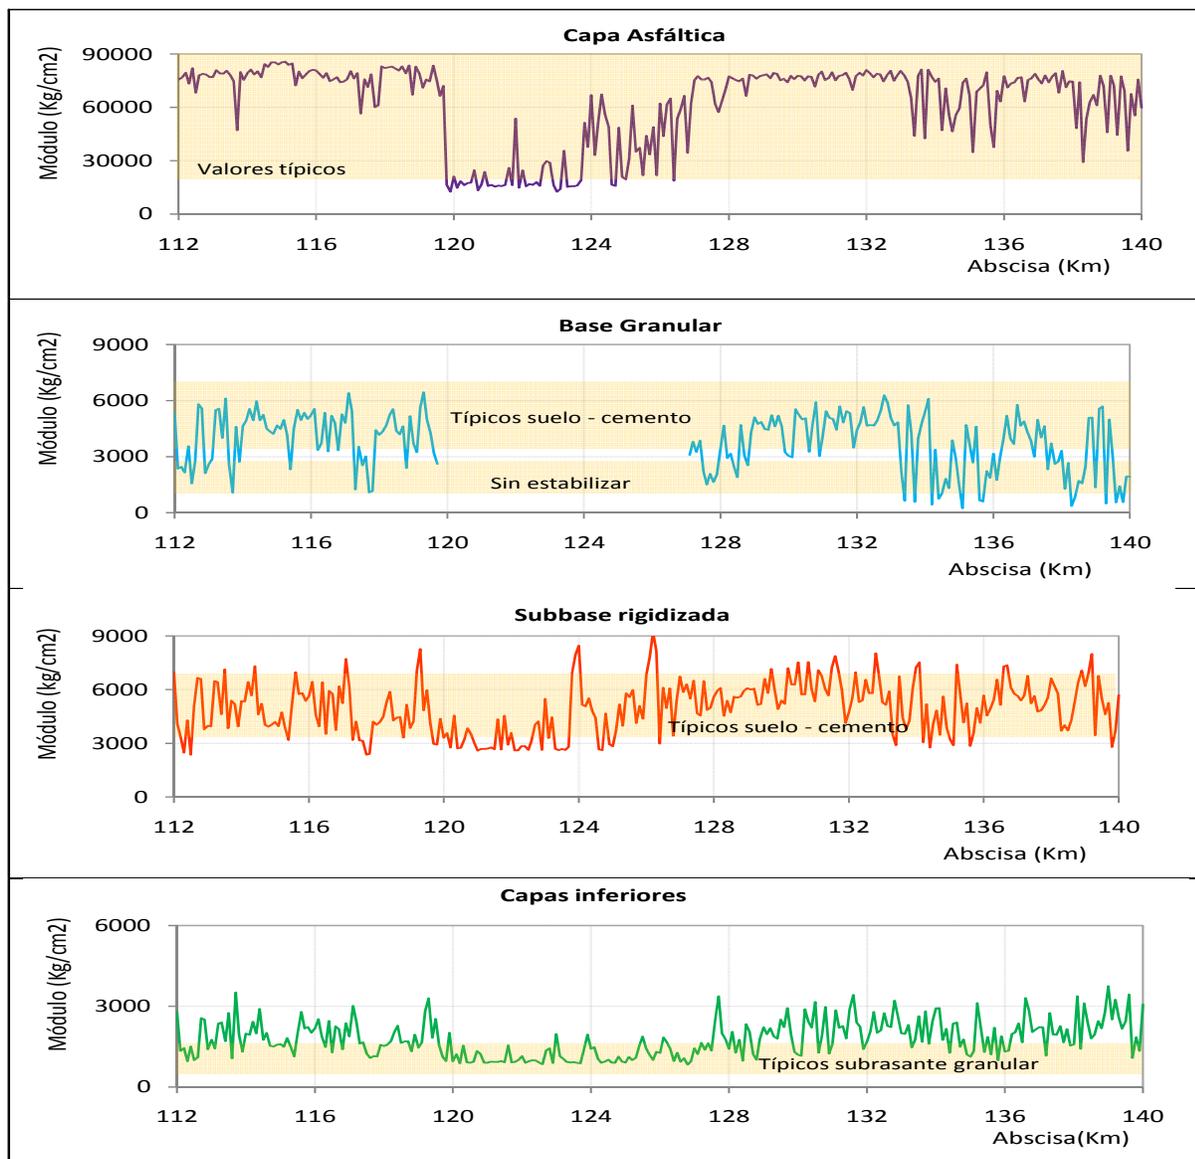


Figura 5.17 Módulos de capa estimados para el carril izquierdo

Se puede apreciar que la mayoría de los módulos estimados mediante la $RNA_{\acute{o}p}$ se encuentran dentro de los valores considerados como típicos para los materiales analizados en este estudio, aunque ocasionalmente se detectan valores catalogados como deficientes o atípicos. Con el ánimo de identificar posibles causas de tales valores, se considera importante comparar los resultados obtenidos con las condiciones reales observadas en el pavimento y con algunos de los indicadores estructurales, tema abordado en los siguientes párrafos.

5.3.5 Análisis de resultados de la modelación con RNAs

En este paso se estudian en detalle los resultados obtenidos con el modelo neuronal propuesto, a la luz de dos aspectos esenciales; en primer lugar, se verifica la coherencia de los resultados con respecto a las condiciones reales que exhibe el pavimento en el carril izquierdo, en cuanto a la variabilidad de espesores, materiales de las capas, deterioro e indicadores estructurales. En segundo término, se realiza un análisis de sensibilidad de las variables para identificar su influencia en los resultados finales obtenidos con la modelación neuronal.

i. Coherencia de los resultados con la condición del pavimento

Contrastando los módulos de capa obtenidos punto a punto a lo largo del carril izquierdo (ilustrados en la Figura 5.17), con las características expuestas en los análisis preliminares (numeral 5.2), es posible verificar la coherencia de las estimaciones con las condiciones reales.

En términos globales, los sitios en los cuales se obtuvieron módulos inferiores a los típicos en todas las capas del pavimento, coinciden con aquellos donde los diferentes indicadores estructurales reflejan condición de rigidez mala o grave.

Al comparar la variación espacial de los módulos estimados para la capa asfáltica con las características del pavimento (Figura 5.3a), se puede apreciar que los sectores con estructura de cuatro capas exhiben valores de módulos alrededor de 75000 kg/cm^2 , los cuales resultan significativamente mayores a los obtenidos para el resto del corredor; la diferencia se atribuye en principio a la presencia de una base asfáltica que forma parte de la capa superficial en el sector intermedio del corredor vial.

Anteriormente se mencionó que el índice BLI se ha utilizado como indicador de la rigidez de las capas superficiales de rodadura y base granular, esencialmente. En consecuencia, se identificó que cuando los módulos en la capa de rodadura son menores de 20000 kg/cm^2 (entre el K119.7 y el K124), BLI indica sitios con condiciones de rigidez grave.

Igualmente, en los sectores donde existe capa de base granular (sistema de cuatro capas), se identifican algunos sitios donde los módulos de la base resultan inferiores a 1000 kg/cm^2 , asociados con los valores de BLI que indican condiciones de riesgo en la rigidez. Aun así, la mayor parte de los módulos superan los valores típicos para bases, debido a un ligero

mejoramiento con cemento Portland en buena parte del corredor, pero sin llegar a niveles de rigidez propios de bases estabilizadas con cemento (17000 a 70000 kg/cm^2).

También se puede observar que los módulos estimados para la base resultan inferiores a los de la subbase rigidizada; este hecho muestra la capacidad del modelo de reproducir las características particulares del sistema de pavimento en esos sectores, donde no se presenta el concepto estructural tradicional de rigidez decreciente con la profundidad.

Los módulos obtenidos en la capa de subbase rigidizada se encuentran dentro de valores típicos observados en materiales estabilizados con cemento (3500 y 7000 kg/cm^2). Todos los sitios donde los módulos de la subbase resultan menores de 3500 kg/cm^2 , coinciden con valores donde el indicador MLI refleja condición de rigidez grave o en riesgo de las capas intermedias.

En cuanto a las capas inferiores, en general se obtienen módulos dentro o superiores al rango típico para subrasantes granulares, lo cual refleja la capacidad óptima de soporte que ofrecen estas capas a la estructura del pavimento en todo el corredor. El índice LLI, asociado con la deformación por compresión sobre las capas inferiores, indica unos cuantos sitios con condición grave cuando los módulos obtenidos son menores de 1000 kg/cm^2 , confirmando que los valores críticos de LLI no necesariamente están asociados con bajos valores de módulos en las capas inferiores, pues cada uno representa características diferentes de los materiales.

De otro lado, a partir de una inspección detallada de las Figura 5.3 (b, c y d), resulta razonable concluir que la condición del pavimento se ve reflejada en los módulos estimados: los sitios que exhiben roderas elevadas o zonas afectadas por deterioro estructural, presentan valores no deseables de módulos en algunas o en todas las capas.

En consecuencia, los bajos módulos obtenidos con RNAs indican zonas que merecen una atención especial al momento de plantear los programas de intervención. Para ayudar a tomar mejores decisiones en ese sentido, los resultados obtenidos en la modelación neuronal se integran posteriormente con otros parámetros cualitativos y cuantitativos, utilizando herramientas de la lógica difusa.

El análisis anterior permite concluir que los módulos estimados con el modelo neuronal pueden utilizarse de manera confiable para caracterizar la rigidez de las capas de pavimento y por tanto, para evaluar la capacidad estructural junto con los demás indicadores de condición.

ii. Análisis de sensibilidad de las variables

Con el fin de identificar el impacto que tienen las variables de entrada a la RNA ópt diseñada para estimar los módulos de capa del pavimento y de entender cómo usa el modelo neuronal la información disponible, se realizó un análisis paramétrico.

Dada la no linealidad del problema analizado, las herramientas de regresión tradicionales no proveen los medios suficientes para determinar la importancia de cada variable de entrada. El análisis de sensibilidad que ofrece el software utilizado en este estudio, se basa en evaluar el cambio que se genera en las salidas (módulos de capa) al remplazar, en cada ejemplo, cada una de las variables de entrada por su valor promedio en todo el conjunto de datos; de esta manera, se tiene en cuenta el rango dinámico de cada variable, considerando que una entrada con un rango pequeño puede tener importancia significativa en las salidas.

El promedio de los cambios obtenidos en las salidas de todos los ejemplos, se promedia para obtener el valor del “efecto” evaluado de manera independiente para cada una de las 16 variables de entrada utilizadas en la RNAópt. Los valores más altos representan variables cuyos cambios impactan de manera importante las salidas.

Para evaluar la importancia relativa de cada entrada, suele dividirse el efecto de cada variable, por el efecto promedio de todas las variables, determinando así el “efecto normalizado (Efecto_N)”; aquellas variables donde el Efecto_N resulte mayor de 1, contribuyen más que el promedio a las salidas de la red. Si todas las entradas tuvieran el mismo impacto, el valor del Efecto_N sería igual a 1.0. En la Tabla 5.9, se presentan los efectos obtenidos para cada una de las variables consideradas.

Tabla 5.9 Análisis de sensibilidad de variables

| VARIABLE | EFECTO | EFECTO _N |
|-----------------|--------------|---------------------|
| Q | 0.06 | 0.29 |
| h ₁ | 0.23 | 1.14 |
| h ₂ | 0.28 | 1.37 |
| h ₃ | 0.12 | 0.60 |
| h ₄ | 0.00 | 0.00 |
| D ₁ | 0.45 | 2.24 |
| D ₂ | 0.32 | 1.58 |
| D ₃ | 0.24 | 1.17 |
| D ₄ | 0.15 | 0.73 |
| D ₅ | 0.26 | 1.25 |
| D ₆ | 0.14 | 0.68 |
| D ₇ | 0.28 | 1.39 |
| v ₁ | 0.23 | 1.15 |
| v ₂ | 0.16 | 0.80 |
| v ₃ | 0.20 | 0.98 |
| v ₄ | 0.13 | 0.65 |
| Promedio | 0.203 | 1.00 |

Para la base de datos utilizada, las variables identificadas con mayor efecto en la estimación de módulos son las deflexiones (excepto D_4 y D_6 medidas a 0.6, y 1.2 m del eje de carga), el espesor de la base granular (h_2) y el espesor (h_1) y relación de Poisson de la capa asfáltica (ν_1). Este último aspecto, soporta aún más la conveniencia de considerar relaciones de Poisson variables para el caso de estudio analizado.

Por el contrario, las variables con menores efectos son la carga, Q y el espesor de las capas inferiores, h_4 . En teoría, estas variables podrían deshabilitarse para disminuir el espacio de entrada a la RNA y por tanto, el costo computacional sin pérdidas significativas en el desempeño. En este estudio sin embargo, los bajos efectos no se interpretan como variables despreciables, sino que se atribuyen a que los dos parámetros prácticamente no varían en los ejemplos utilizados; por tanto, se mantienen habilitados para extender el uso potencial de la red diseñada hacia la estimación de módulos en estructuras de pavimentos donde Q y h_4 tengan intervalos dinámicos más amplios.

5.4 Evaluación estructural del pavimento usando herramientas de la LD

En este numeral se incluyen las actividades tendientes a caracterizar el pavimento desde los enfoques de **rigidez** y de **deterioro**, los cuales evalúan características diferentes del pavimento, pero se complementan para lograr la descripción integral de la **condición estructural**; en función de ello, se definen las soluciones para mantener en buen estado el pavimento.

Para abordar estos problemas, se plantean dos Sistemas de Inferencia Difusa – SIDs que permitan identificar, de manera independiente, la condición de rigidez y de deterioro que se pueda encontrar en el corredor.

5.4.1 Diseño de los Sistemas de Inferencia Difusa - SIDs

En los problemas específicos a resolver con los dos sistemas, se pretende involucrar el conocimiento de expertos en la evaluación de pavimentos. Para ello, resulta adecuado el planteamiento de sistemas con el mecanismo de inferencia propuesto por Mandami (ver Figura 4.12), donde las salidas están representadas por conjuntos difusos con sus respectivas funciones de pertenencia que se traducen en valores reales o decisiones asociadas con las mismas.

En ambos casos, el conocimiento y la experiencia representa la fuente principal para definir las funciones de pertenencia y las reglas difusas. Para el caso de estudio, no se considera conveniente el uso de sistemas automáticos de aprendizaje para definir o refinar las funciones de pertenencia de conceptos que transmiten una descripción lingüística y subjetiva, pues difícilmente podría reflejarse el conocimiento y la experiencia en las salidas deseadas (Jang, 1993).

A continuación se describe en detalle el diseño de los dos sistemas de inferencia planteados para evaluar las condiciones de rigidez y de deterioro.

Sistema para evaluar la rigidez - $SID_{Rigidez}$

Las seis variables de entrada seleccionadas para evaluar la rigidez son **D_{máx}**, representativa de la capacidad global, los módulos de capa **E1, E2, E3** y los índices **BLI y MLI** indicadores de la capacidad de cada capa; se integran así parámetros mecánicos e indicadores deducidos a partir de cuencas de deflexión. El módulo de las capas inferiores **E4** no se consideró en el diseño del modelo difuso, pues para el caso de estudio que se está analizando, los altos valores obtenidos no reflejan deficiencia alguna de rigidez asociada con estas capas (ver Figura 5.17).

Para cada variable se establecieron categorías expresadas en términos lingüísticos, cuya representación difusa se efectuó teniendo en cuenta las opiniones de expertos plasmadas en la Tabla 3.1, Tabla 3.2 y Tabla 3.7 (ARA Inc. y ERES Consultants, 2004 - ASTM, 2003; Barrantes *et al*, 2008; Horak y Emery, 2006).

Los módulos de cada capa se discriminaron en las categorías bajo, medio y alto; la $D_{máx}$ se catalogó como buena, en riesgo, grave y severa; los índices BLI y MLI se clasificaron como bueno, en riesgo y grave.

Como producto de posibles combinaciones de las variables de entrada, se establecieron categorías que califican la rigidez a la salida del sistema, descritas también en términos lingüísticos como adecuada, en riesgo, regular, mala y pésima; las dos últimas se dividieron en las sub-categorías 1, 2 y 3 para identificar si las deficiencias afectan toda la estructura, las dos capas superiores o sólo la capa más superficial; esto con el fin orientar posteriormente las alternativas de conservación y mantenimiento. Se plantean entonces, nueve posibles categorías finales de la condición por rigidez.

En la Figura 5.18 se muestra el sistema de inferencia planteado para evaluar la rigidez del pavimento, los conjuntos difusos y funciones de pertenencia propuestos para cada variable. Por simplicidad, en la mayoría de los casos se plantean funciones de pertenencia con forma triangular.

La correspondencia entre las variables de entrada y la rigidez en la salida, se estableció a través de un sistema de reglas de inferencia con base en los criterios planteados en la Tabla 5.10. Las condiciones extremas estarían dadas por rigidez **adecuada** y rigidez **pésima 1**; dentro de estos dos límites, se definen condiciones intermedias que describen las diversas posibilidades que se pueden encontrar.

La condición **adecuada**, se da cuando los valores de módulos de capa se encuentran dentro de los rangos “medio a alto” y los indicadores de rigidez están en la categoría “bueno”. En estos casos, no se identifican deficiencias asociadas con la rigidez de las capas; la aplicación de

conservación y mantenimiento estaría condicionada a la presencia de algún tipo de daño, pero es de esperarse intervenciones netamente superficiales.

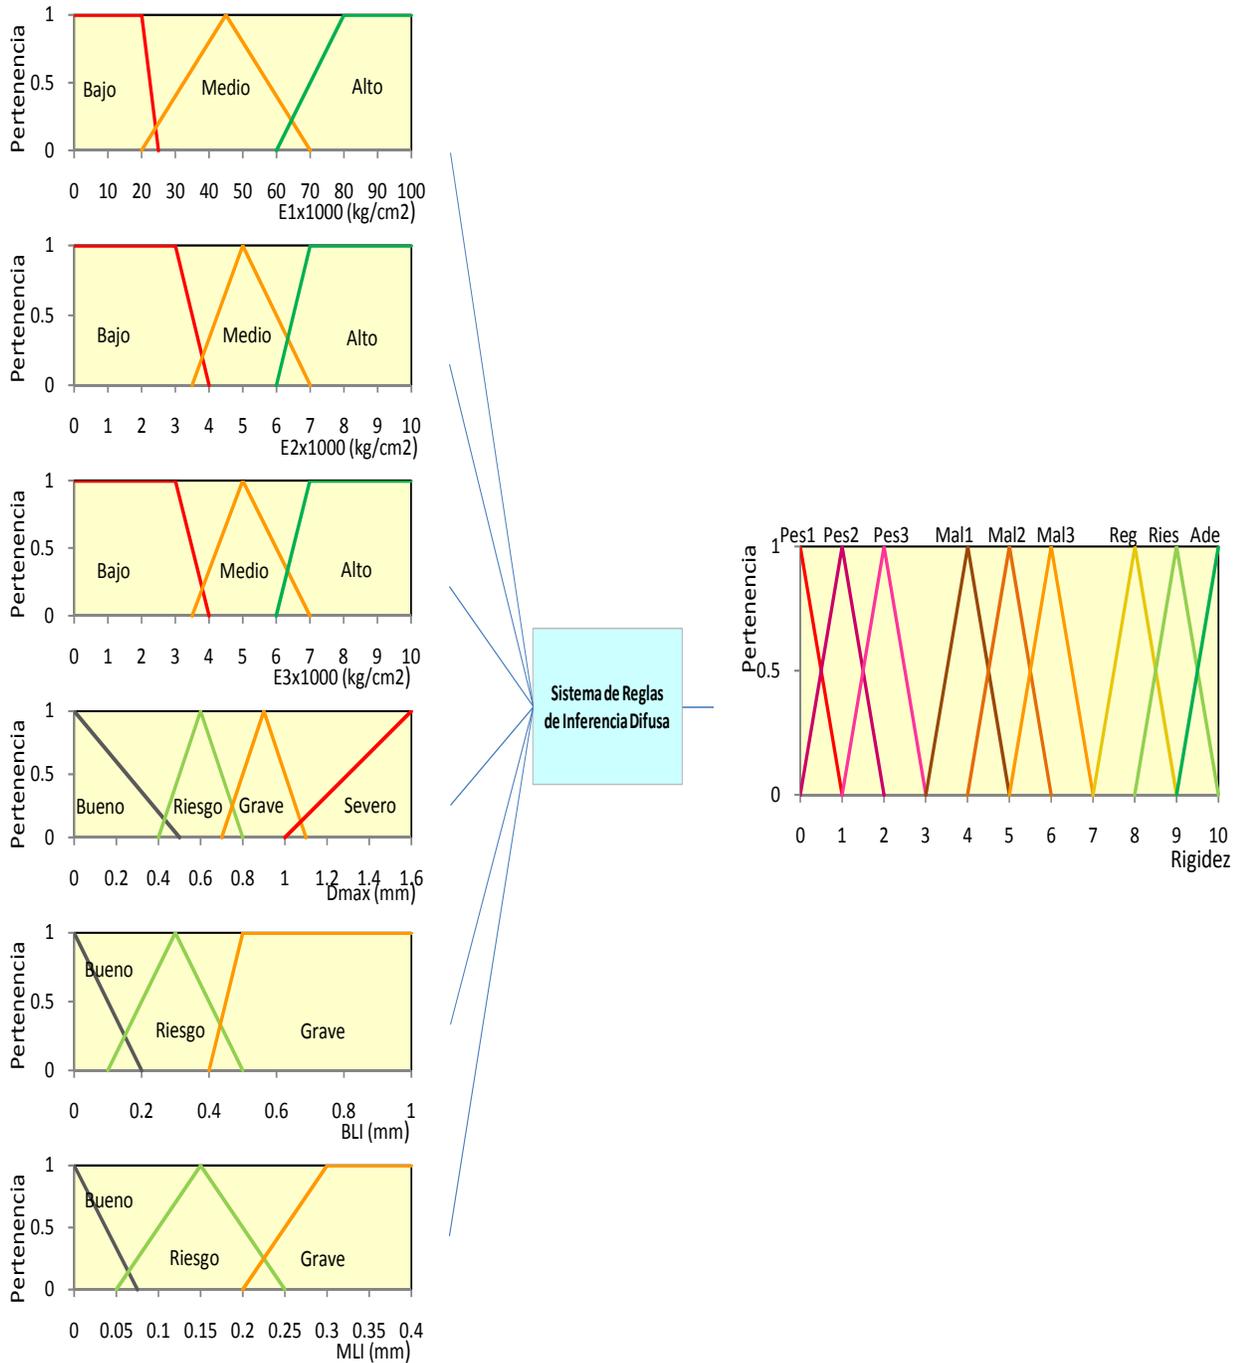


Figura 5.18 Sistema de inferencia para evaluar la rigidez

Por su parte, la condición **pésima1** se alcanza cuando el módulo de la subbase es “bajo”, D_{máx} es “severa” y MLI “grave”. Con esto se quiere representar situaciones donde las capas internas

del pavimento contribuyen de manera significativa en la deficiencia global de toda la estructura. En estos casos, es de esperarse que las soluciones incluyan refuerzo estructural, e incluso recuperación de las capas internas, las cuales obviamente están sujetas a la presencia, magnitud y severidad de algún deterioro.

Tabla 5.10 Consideraciones para el sistema de reglas de inferencia - rigidez

| SI MÓDULOS | Y SI INDICADORES | SUBCATEGORÍA | RIGIDEZ |
|---------------|---|-----------------|----------|
| E1 y E3 bajos | Dmax severa | CA y SB pésima | Pésima 1 |
| E2 Y E3 bajos | MLI grave y Dmax severa | BG Y SB pésima | |
| E3 bajo | MLI grave y Dmax severa | SB pésima | |
| E1 y E2 bajos | BLI grave y Dmax severa | CA y BG pésima | Pésima 2 |
| E2 bajo | BLI grave y Dmax severa | BG pésima | |
| E1 bajo | BLI grave y Dmax severa | CA pésima | Pésima 3 |
| E1 y E3 bajos | Dmax grave | CA y SB mala | Mala 1 |
| E2 Y E3 bajos | MLI grave | BG y SB mala | |
| E3 bajo | MLI grave | SB mala | |
| E1 y E2 bajos | BLI grave | CA y BG mala | Mala 2 |
| E2 bajo | BLI grave | BG mala | |
| E1 bajo | BLI grave | CA mala | Mala 3 |
| E1 y E3 bajos | Dmax riesgo | CA y SB regular | Regular |
| E2 Y E3 bajos | MLI riesgo | BG y SB regular | |
| E1 y E2 bajos | BLI riesgo | CA y BG regular | |
| E3 bajo | MLI riesgo | SB regular | |
| E2 bajo | BLI riesgo | BG regular | |
| E1 bajo | BLI riesgo | CA regular | |
| Ninguno bajo | Algún indicador severo, grave o en riesgo | En riesgo | Riesgo |
| Ninguno bajo | Ninguno | Adecuada | Adecuada |

Sistema para evaluar deterioro - *SID_{Deterioro}*

En el sistema de inferencia planteado para evaluar la condición por deterioro, las cuatro variables de entrada consideradas son la profundidad de **roderas**, asociada con problemas de *deformación*, **las grietas**, **baches abiertos** y **baches reparados**, relacionados con fenómeno de *rotura* del pavimento.

En la práctica común, cada tipo de daño se clasifica, según su intensidad, en adecuada, ligera, media y severa, cuyos límites detonan diferentes niveles de intervención; la representación difusa de estos términos lingüísticos y su dominio en la escala de los números reales, se definió teniendo en cuenta las opiniones de expertos consignadas en la Tabla 3.8 a la Tabla 3.12 (ARA Inc. y ERES Consultants, 2004; LCPC, 1991; Orozco, 2005).

La salida del sistema difuso está constituida por categorías de deterioro, las cuales integran las posibles combinaciones de variables de entrada, considerando que un pavimento puede estar afectado por deformaciones, roturas o ambos. La escala de calificación se representa mediante conjuntos difusos, expresados también en términos lingüísticos.

En la definición de estas categorías también se consideró su aplicación en la toma de decisiones sobre el tipo de intervención a ejecutar, pues en la práctica las acciones están sujetas a la presencia, tipo e intensidad del deterioro. Se definieron entonces, ocho categorías esperadas de la condición por deterioro: rotura severa, rotura media, grietas ligeras, baches ligeros, deformación severa, deformación media, deformación ligera y condición adecuada.

En la Figura 5.19 se muestra el sistema de inferencia diseñado para evaluar la condición de deterioro, con los respectivos conjuntos difusos y funciones de pertenencia propuestos tanto para las variables de entrada como para la salida.

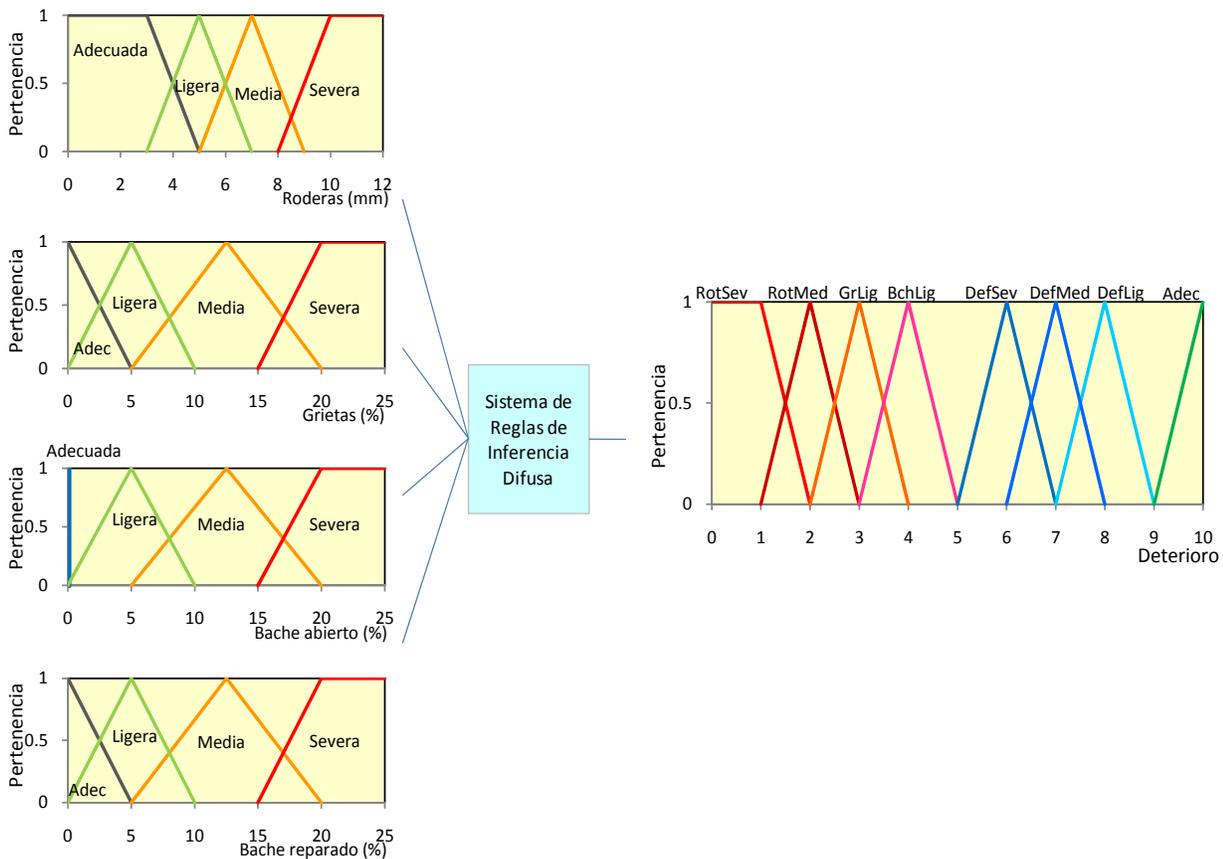


Figura 5.19 Sistema de inferencia difuso para evaluar el deterioro

El sistema de reglas de inferencia que articula las entradas y las salidas se estableció con base en las condiciones sintetizadas en la Tabla 5.11. Para este caso, se considera que si se presentan

simultáneamente fenómenos de rotura y deformaciones severas o medias, la condición final que prevalece es la rotura, puesto que las soluciones que se plantean para corregirlas, también corrigen los problemas de deformación. Este mismo criterio se aplicó cuando se presentan simultáneamente todos los daños con intensidad ligera.

Tabla 5.11 Consideraciones para el sistema de reglas de inferencia por deterioro

| SI | O | COND. POR DETERIORO |
|-----------------------------------|-----------------------------------|---------------------|
| Grietas o Baches severos | Grietas y Baches medios | Rotura severa |
| Grietas y Roderas medias | Baches y Roderas medias | |
| Grietas o Baches medios | Grietas y Baches ligeros | Rotura media |
| Grietas medias y baches ligeros | Baches medios y grietas ligeras | |
| Grietas y Roderas ligeras | Baches y Roderas ligeras | |
| Grietas, baches y roderas ligeras | | |
| Grietas ligeras | | Grietas ligeras |
| Baches ligeros | | Baches ligeros |
| Roderas severas | Roderas severas y grietas ligeras | Deformación severa |
| Roderas medias | Roderas medias y grietas ligeras | Deformación media |
| Roderas ligeras | | Deformación ligera |
| Ninguno | | Adecuada |

5.4.2 Evaluación de los SIDs diseñados – Análisis de resultados

Los SIDs diseñados se evaluaron utilizando los datos disponibles en el carril izquierdo del caso de estudio que se ha venido analizando.

Los módulos de capa estimados con el modelo de RNAs e índices deducidos a partir de las 280 cuencas de deflexión medidas se introdujeron como variables de entrada al SID_{Rigidez}. Por su parte, el SID_{Deterioro} se evaluó introduciendo los datos medidos sobre el corredor en cuanto a grietas, roderas, baches abiertos y baches reparados.

Para cada conjunto de datos introducido en el SID_{Rigidez} y el SID_{Deterioro}, se obtuvieron los valores numéricos que caracterizan cada condición del pavimento, con sus correspondientes términos lingüísticos asociados. Vale la pena mencionar que una vez introducidos los datos en cada SID, los resultados se obtienen en unos cuantos segundos.

En cada caso, se efectuó un análisis de sensibilidad para evaluar diferentes técnicas de “defusificación” en la obtención de las salidas numéricas; para ello, se probaron los métodos del centro de gravedad, bisección del área y el promedio de los máximos.

Mediante una revisión punto a punto se validaron las salidas numéricas de cada SID, verificando su coherencia con las condiciones ya evaluadas de los parámetros e indicadores de rigidez. Para los problemas aquí analizados, se encontró que el método de bisección del área suministró

calificaciones que se ajustaron 100% a las condiciones de rigidez esperadas. En la Tabla 5.12 se consignan los resultados del $SID_{Rigidez}$ para un tramo de tres kilómetros de vía.

Tabla 5.12 Condición por rigidez del pavimento a partir del $SID_{Rigidez}$

| ABSCISA (Km) | E1 * 1000 (kg/cm ²) | E2* 1000 (kg/cm ²) | E3* 1000 (kg/cm ²) | Dmax (mm) | BLI (mm) | MLI (mm) | SALIDA NUMÉRICA | RIGIDEZ |
|--------------|---------------------------------|--------------------------------|--------------------------------|-----------|----------|----------|-----------------|----------|
| 119.1 | 71.03 | 3.24 | 4.22 | 0.49 | 0.21 | 0.09 | 8.2 | Regular |
| 119.2 | 75.61 | 5.63 | 7.07 | 0.31 | 0.16 | 0.05 | 9.6 | Adecuada |
| 119.3 | 74.59 | 6.45 | 8.26 | 0.21 | 0.12 | 0.04 | 9.6 | |
| 119.4 | 83.44 | 4.99 | 4.84 | 0.38 | 0.13 | 0.06 | 9.4 | |
| 119.5 | 75.46 | 4.25 | 5.96 | 0.39 | 0.21 | 0.09 | 9.0 | Riesgo |
| 119.6 | 66.52 | 3.18 | 4.12 | 0.62 | 0.27 | 0.14 | 8.1 | Regular |
| 119.7 | 72.15 | 2.62 | 2.97 | 0.67 | 0.25 | 0.17 | 8.0 | Mala 1 |
| 119.8 | 16.34 | | 2.93 | 0.97 | 0.47 | 0.18 | 4.0 | |
| 119.9 | 12.58 | | 4.35 | 0.69 | 0.42 | 0.16 | 7.8 | Regular |
| 120.0 | 21.05 | | 3.31 | 0.86 | 0.42 | 0.16 | 8.0 | |
| 120.1 | 14.79 | | 3.56 | 0.62 | 0.32 | 0.12 | 8.0 | Mala 1 |
| 120.2 | 18.49 | | 2.76 | 0.83 | 0.33 | 0.17 | 4.0 | |
| 120.3 | 16.24 | | 4.54 | 0.55 | 0.31 | 0.10 | 8.0 | Regular |
| 120.4 | 17.38 | | 2.72 | 1.05 | 0.44 | 0.22 | 3.8 | Mala 1 |
| 120.5 | 17.66 | | 2.75 | 0.82 | 0.37 | 0.14 | 4.0 | |
| 120.6 | 24.70 | | 3.21 | 0.62 | 0.27 | 0.11 | 8.2 | Regular |
| 120.7 | 13.35 | | 3.83 | 0.69 | 0.41 | 0.09 | 7.9 | |
| 120.8 | 16.51 | | 3.51 | 0.62 | 0.37 | 0.11 | 8.0 | |
| 120.9 | 23.60 | | 3.02 | 0.79 | 0.32 | 0.18 | 7.7 | |
| 121.0 | 15.73 | | 2.60 | 1.11 | 0.50 | 0.33 | 0.4 | Pésima1 |
| 121.1 | 16.39 | | 2.68 | 0.87 | 0.42 | 0.23 | 4.0 | Mala 1 |
| 121.2 | 15.32 | | 2.68 | 1.58 | 0.91 | 0.30 | 0.3 | Pésima1 |
| 121.3 | 16.02 | | 2.70 | 0.76 | 0.37 | 0.17 | 4.6 | Mala 1 |
| 121.4 | 15.76 | | 2.76 | 0.72 | 0.37 | 0.17 | 7.8 | Regular |
| 121.5 | 16.35 | | 2.67 | 1.00 | 0.45 | 0.17 | 4.0 | Mala 1 |
| 121.6 | 25.89 | | 4.33 | 0.35 | 0.19 | 0.04 | 9.6 | Adecuada |
| 121.7 | 16.29 | | 2.66 | 0.93 | 0.40 | 0.19 | 4.0 | Mala 1 |
| 121.8 | 53.70 | | 4.54 | 0.59 | 0.23 | 0.10 | 9.0 | Riesgo |
| 121.9 | 14.87 | | 2.92 | 0.75 | 0.39 | 0.12 | 4.9 | Mala 2 |
| 122.0 | 24.50 | | 3.57 | 0.58 | 0.27 | 0.08 | 8.7 | Regular |

Los sitios críticos de rigidez se ubican en el K121 y el K121.3, con módulos bajos y valores altos de los indicadores $D_{máx}$, BLI y MLI. En estos sitios se obtuvieron calificaciones de 0.3 y 0.4 que indican rigidez Pésima1 según las salidas del sistema mostrado en la Figura 5.18.

Los resultados obtenidos mediante el $SID_{Deterioro}$ para el mismo tramo, se consignan en la Tabla 5.13; la condición más desfavorable se identifica entre el K119.8 y el K 120.2, con calificaciones de 6.4 a 7, que indican deformaciones medias-severas y calificaciones del orden de 2.5 (rotura media-ligera), de acuerdo con las salidas del sistema mostrado en la Figura 5.19.

Tabla 5.13 Deterioro del pavimento a partir del SID-Deterioro

| ABSCISA (Km) | Roderas (mm) | GRIETAS (%) | BACHE ABIER. (%) | BACHE REP. (%) | SALIDA NUMÉRICA | DETERIORO | |
|--------------|--------------|-------------|------------------|----------------|-----------------|-------------------------------|---------------|
| 119.1 | 0 | 0 | 0 | 0 | 9.7 | Adecuada | |
| 119.2 | 0 | 0 | 0 | 0 | 9.7 | | |
| 119.3 | 0 | 0 | 0 | 0 | 9.7 | | |
| 119.4 | 0 | 0 | 0 | 0 | 9.7 | | |
| 119.5 | 0 | 0 | 0 | 0 | 9.7 | | |
| 119.6 | 0 | 0 | 0 | 0 | 9.7 | | |
| 119.7 | 3.9 | 0 | 0 | 0 | 8.6 | Deform ligera | |
| 119.8 | 7.7 | 5 | 0 | 0 | 7.0 | Deformación media-severa | |
| 119.9 | 8.6 | 5 | 0 | 0 | 6.4 | Rotura media, grietas ligeras | |
| 120.0 | 0 | 8 | 0 | 0 | 2.5 | | |
| 120.1 | 3.7 | 5 | 0 | 0 | 2.6 | Grietas ligeras | |
| 120.2 | 0 | 5 | 0 | 0 | 3.0 | | |
| 120.3 | 0 | 0 | 0 | 0 | 9.7 | Adecuada | |
| 120.4 | 0 | 0 | 0 | 0 | 9.7 | | |
| 120.5 | 0 | 0 | 0 | 0 | 9.7 | | |
| 120.6 | 0 | 0 | 0 | 0 | 9.7 | | |
| 120.7 | 0 | 0 | 0 | 0 | 9.7 | | |
| 120.8 | 0 | 0 | 0 | 0 | 9.7 | | |
| 120.9 | 0 | 0 | 0 | 0 | 9.7 | | |
| 121.0 | 3.3 | 0 | 0 | 0 | 9.1 | | |
| 121.1 | 5.3 | 0 | 0 | 0 | 7.8 | | Deform ligera |
| 121.2 | 5.5 | 0 | 0 | 0 | 7.7 | | |
| 121.3 | 4.4 | 0 | 0 | 0 | 8.4 | Adecuada | |
| 121.4 | 0 | 0 | 0 | 0 | 9.7 | | |
| 121.5 | 0 | 0 | 0 | 0 | 9.7 | | |
| 121.6 | 3.3 | 0 | 0 | 0 | 9.1 | | |
| 121.7 | 0 | 0 | 0 | 0 | 9.7 | | |
| 121.8 | 0 | 0 | 0 | 0 | 9.7 | | |
| 121.9 | 0 | 0 | 0 | 0 | 9.7 | | |
| 122.0 | 0 | 0 | 0 | 0 | 9.7 | | |

5.4.3 Identificación de sectores homogéneos

Con base en la caracterización del pavimento lograda mediante LD, cuyos resultados se incluyen en el Anexo B, se elaboró la Figura 5.20 para ilustrar la variación de las calificaciones obtenidas a lo largo del corredor, representadas en escala numérica y de colores, con los correspondientes términos lingüísticos asociados. Para efectos de visualización, se presentan las categorías de rigidez pésima, mala y regular y deterioro severo, medio y ligero. Adicionalmente, se superponen los sectores homogéneos de comportamiento definidos en el numeral 5.2.

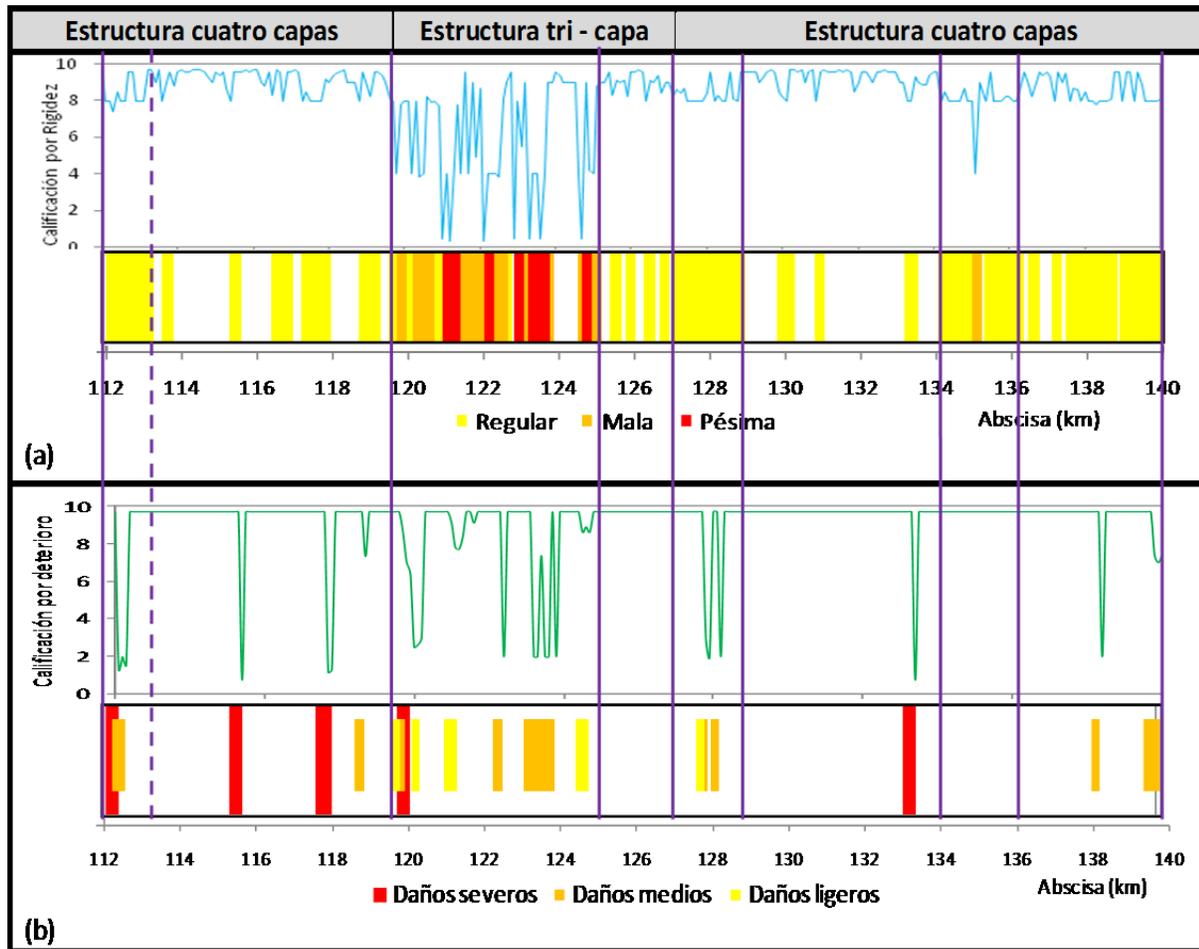


Figura 5.20 Caracterización estructural del corredor
(a) según el $SID_{Rigidez}$; (b) Según el $SID_{Deterioro}$

En general, se puede apreciar que los cambios más significativos en las condiciones de rigidez están asociados con variaciones en la estructura del pavimento y con las fronteras definidas mediante diferencias acumuladas; solamente se identifica un subsector adicional en el tramo inicial, para un total de ocho sectores homogéneos.

Se evidencia entonces que la definición de sectores en el corredor está estrechamente relacionada con la evaluación del comportamiento mecánico del pavimento, cuya caracterización se logró de manera bastante efectiva mediante el $SID_{Rigidez}$.

En la Tabla 5.14 se presenta un resumen con la distribución porcentual de las diferentes categorías de rigidez y de deterioro para los ocho sectores identificados a lo largo del corredor. Con base en los datos de esta tabla y en la Figura 5.20, se puede establecer que los sectores 2 y 6 presentan las mejores condiciones simultáneas de rigidez y de deterioro, salvo eventuales daños severos localizados.

Tabla 5.14 Clasificación de la condición de rigidez y deterioro por sector (%)

| Sector | Desde el km | Hasta el km | Condición por rigidez | | | | | Condición por deterioro | | | |
|--------------|-------------|-------------|-----------------------|-----------|-----------|----------|----------|-------------------------|----------|----------|----------|
| | | | Adec | Ries | Regul | Mala | Pés | Adec | Ligero | Medio | Sever |
| 1 | 112.2 | 113.2 | 25 | 0 | 75 | 0 | 0 | 75 | 0 | 17 | 8 |
| 2 | 113.2 | 119.7 | 60 | 20 | 20 | 0 | 0 | 93 | 0 | 2 | 5 |
| 3 | 119.7 | 125.1 | 7 | 19 | 24 | 37 | 13 | 64 | 15 | 19 | 2 |
| 4 | 125.1 | 127.0 | 30 | 50 | 20 | 0 | 0 | 100 | 0 | 0 | 0 |
| 5 | 127.0 | 128.9 | 13 | 13 | 74 | 0 | 0 | 81 | 6 | 13 | 0 |
| 6 | 128.9 | 134.2 | 67 | 18 | 15 | 0 | 0 | 98 | 0 | 0 | 2 |
| 7 | 134.2 | 136.3 | 5 | 10 | 80 | 5 | 0 | 100 | 0 | 0 | 0 |
| 8 | 136.3 | 140.0 | 32 | 21 | 47 | 0 | 0 | 89 | 0 | 11 | 0 |
| Total | | | 36 | 20 | 33 | 8 | 3 | 88 | 3 | 7 | 2 |

En los sectores 4 y 7 la condición por rigidez refleja ciertas deficiencias del pavimento, aunque no están afectados por deterioro; esto indica que para las condiciones de carga actual la vía opera satisfactoriamente y no requiere intervenciones inmediatas, pero sí efectuar seguimiento periódico para detectar el deterioro de manera temprana.

Por su parte, el sector 3 exhibe las peores condiciones tanto de rigidez como de deterioro; 50% de su longitud exhibe rigidez mala a pésima y 36% de deterioro ligero a severo. En esta situación, se requerirán acciones que corrijan los defectos, pero que a su vez incrementen la capacidad estructural.

La condición por rigidez en el sector 1 no llega a ser crítica, pero presenta la mayor cantidad de deterioro severo a medio (25%), requiriendo acciones correctivas inmediatas en sitios localizados y monitoreo para evitar llevar a condiciones críticas de rigidez. Algo similar podría aplicarse en los tramos 5 y 8, donde existe deterioro medio de 13 y 11%, respectivamente y condiciones de rigidez adecuada a regular.

Aunque la definición de los sectores homogéneos no se fundamenta propiamente en las condiciones de deterioro, éstas sí resultan esenciales para la formulación de las prácticas de mantenimiento más apropiadas, según se expone en el siguiente numeral.

5.5 Definición de Soluciones

Una vez caracterizado el corredor e identificado las deficiencias estructurales, se definen las acciones de rehabilitación y mantenimiento necesarias para corregirlas o controlarlas. A continuación se presenta un resumen de las principales acciones que se pueden considerar, para diseñar posteriormente un SID_{Soluciones} útil para la asignación de intervenciones en función de la condición integral de rigidez y de deterioro, el cual, se evalúa finalmente para el caso de estudio que se está analizando.

5.5.1 Intervenciones Potenciales

La definición de posibles soluciones se realizó teniendo en cuenta las acciones contempladas en las normas de la SCT, consignadas en la Tabla 5.15, y las recomendaciones de experiencias exitosas en conservación de pavimentos, encontradas en estudios previos a nivel local e internacional expuestas en el capítulo 3.

Tabla 5.15 Principales Actividades de mantenimiento según SCT

| 1. Rutinario | | |
|--------------------------|---|-----------------------|
| 1.1 | Limpieza de la Superficie de Rodamiento y Acotamientos | N·CSV·CAR·2·02·001/00 |
| 1.2 | Sellado de Grietas Aisladas en Carpetas Asfálticas | N·CSV·CAR·2·02·002/00 |
| 1.3 | Bacheo Superficial Aislado | N·CSV·CAR·2·02·003/00 |
| 1.4 | Bacheo Profundo Aislado | N·CTR·CAR·2·02·004/00 |
| 2. Periodico | | |
| 2.1 | Renivelaciones Locales | N·CSV·CAR·3·02·001/00 |
| 2.2 | Capas de Rodadura de un Riego | N·CSV·CAR·3·02·002/09 |
| 2.3 | Carpetas de Granulometría Abierta | N·CSV·CAR·3·02·003/00 |
| 2.4 | Capas de Rodadura de Mortero Asfáltico | N·CSV·CAR·3·02·004/09 |
| 2.5 | Carpeta Asfáltica de Granulometría Densa | N·CSV·CAR·3·02·005/06 |
| 2.6 | Fresado de la superficie de rodadura en pavimentos asfálticos | N·CSV·CAR·3·02·006/06 |
| 2.7 | Recorte de Carpetas Asfálticas | N·CSV·CAR·3·02·007/03 |
| 2.8 | Recuperación en Caliente de Carpetas Asfálticas (reciclado) | N·CSV·CAR·3·02·008/03 |
| 3. Reconstrucción | | |
| 3.1 | Recuperación en Frío de Pavimentos Asfálticos | N·CSV·CAR·4·02·001/03 |
| 3.2 | Recorte de Pavimentos | N·CSV·CAR·4·02·003/03 |
| 3.3 | Construcción de Subbases o Bases Hidráulicas | N·CSV·CAR·4·02·004/03 |
| 3.4 | Construcción de Subbases o Bases Estabilizadas | N·CSV·CAR·4·02·005/03 |

Fuente: Normas N-CSV-CAR, SCT

Como producto de la revisión de las diferentes recomendaciones y criterios de selección, se identificaron cinco grupos de intervenciones, clasificadas en reconstrucción, reciclado, refuerzo estructural, restauración superficial o reparaciones localizadas. En la Tabla 5.16, se resumen algunas de las acciones que se pueden aplicar en cada categoría.

La solución a seleccionar, está sujeta a la condición específica que exhibe el pavimento, a la luz de los indicadores de condición que se empleen para la evaluación estructural. En la medida en que se involucre mayor cantidad de indicadores y se amplíe el espectro de intervenciones para la toma de decisiones, las acciones a recomendar tendrán mayores alcances.

Tabla 5.16 Listado de posibles intervenciones

| GLOBAL | ACCIONES ESPECÍFICAS |
|---------------------------------|---|
| Reconstrucción | <i>Total.</i> Comprende la demolición y recuperación de las capas granulares y asfálticas con opción de sección tradicional o invertida |
| | <i>Parcial.</i> Demolición y recuperación de capa asfáltica y base granular |
| | <i>Superficial.</i> Demolición y recuperación de la capa asfáltica |
| Reciclado | En caliente o en frío |
| Refuerzo estructural | Sobrecarpeta asfáltica con o sin polímero |
| | Fresado y reposición de carpeta asfáltica |
| | Whitetopping, previa renivelación y tratamiento de zonas deterioradas |
| Restauración superficial | Rejilla en fibra de vidrio superficial y microcarpeta |
| | Microcarpeta. |
| | Microcarpeta con fresado si existen grietas y baches |
| | Sello con mortero asfáltico |
| | Tratamiento superficial simple o doble |
| | Sello arena asfalto |
| Locales | Sello de grietas con o sin calafateo, dependiendo de la abertura |
| | Bacheo |
| | Renivelación local de zonas con roderas |

5.5.2 Sistema de inferencia para las soluciones - $SID_{\text{Soluciones}}$

Ante la eficiencia mostrada por los dos sistemas de inferencia previamente diseñados, se propone un tercer SID que integra los criterios de rigidez y deterioro, para lograr una caracterización que permita formular soluciones acordes con las dos condiciones.

Los conjuntos difusos y los respectivos términos lingüísticos de las calificaciones propuestas en el SID_{Rigidez} y el $SID_{\text{Deterioro}}$, conforman ahora las entradas al $SID_{\text{Soluciones}}$. La salida está constituida por una calificación según las combinaciones de variables de entrada, considerando que un pavimento puede estar afectado por daños o deficiencias de rigidez o ambos. Se definió una escala de calificación de 0 a 100, con el planteamiento inicial mostrado en la Tabla 5.17.

Tabla 5.17 Escala de calificación y acciones globales

| CONDICIÓN INTEGRAL | CALIFICACIÓN | ACCIÓN |
|--------------------|--------------|--------------------|
| Pésima | 0 a 15 | Reconstrucción |
| Mala | 15 a 40 | Refuerzo |
| Regular | 40 a 60 | Restauración |
| Buena | 60 a 90 | Reparación locales |
| Excelente | 90 a 100 | Monitoreo o Nada |

Los valores más altos representan pavimentos en excelente estado que no requieren intervención, mientras las calificaciones más bajas se asocian a las peores condiciones donde se requieren reconstrucción.

Se debe resaltar que no existen criterios rígidos para optar por alguna de las acciones sugeridas y queda abierta la posibilidad para involucrar más soluciones al sistema diseñado.

Para mayor utilidad práctica, cada categoría se subdividió para dar cabida a acciones específicas que orienten mejor las decisiones en las salidas; las diferentes sub-categorías de calificación quedan expresadas en términos lingüísticos que describen las recomendaciones finales factibles de realizarse para mantener el pavimento en estado adecuado.

En la Figura 5.21 se muestra el sistema de inferencia diseñado para la asignación de soluciones según la condición estructural integral, con los términos lingüísticos y los conjuntos difusos planteados para la calificación estructural en la salida.

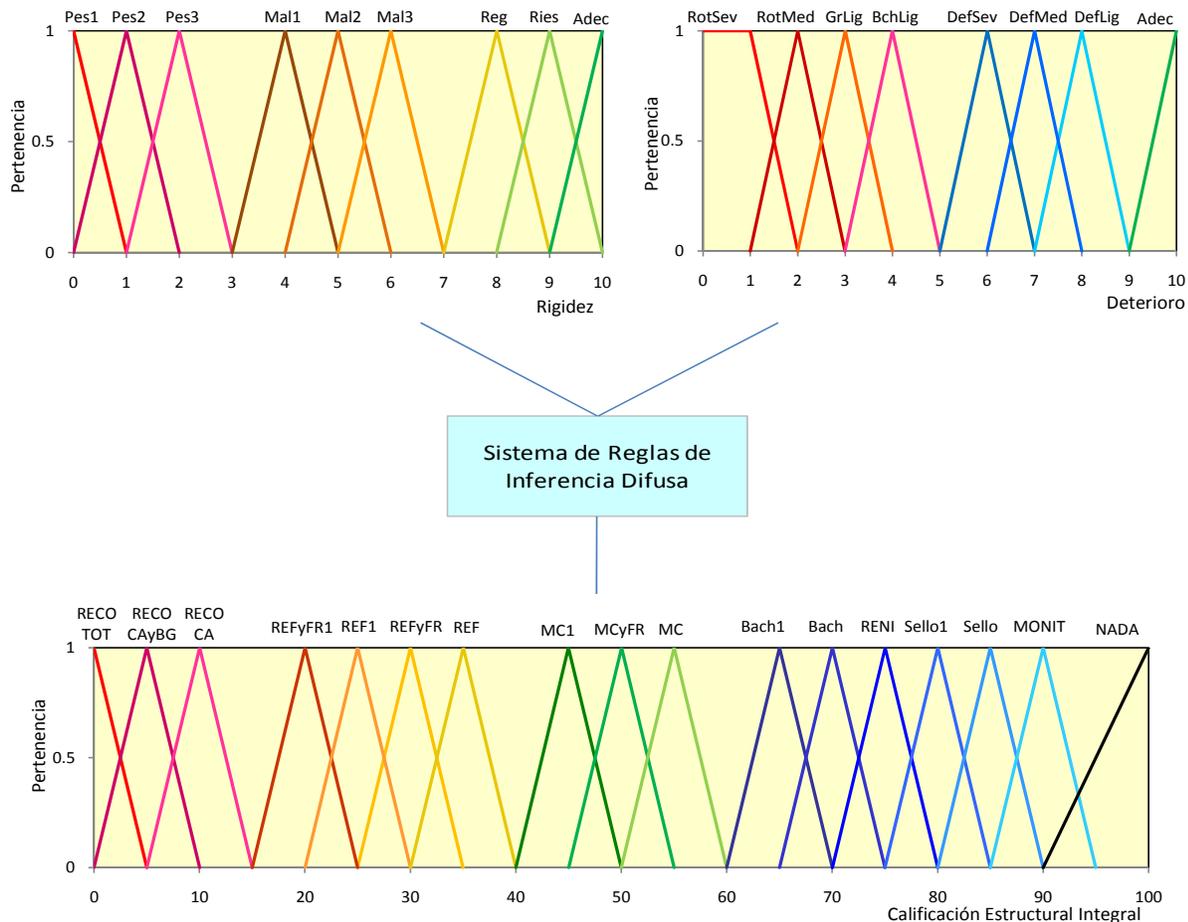


Figura 5.21 Sistema de inferencia difuso para la evaluación integral

En la Tabla 5.18 se presenta la matriz de decisiones diseñada para generar el sistema de reglas de inferencia en función de las posibles combinaciones de rigidez y de deterioro; en ella se plantean las condiciones específicas que deben darse para optar por cada acción.

Tabla 5.18 Matriz de decisión para el sistema de reglas - SIDSoluciones

| RIGIDEZ | DETERIORO | | | | | | | | | |
|----------|---------------------------------------|-------------------|--|---|--|---|--|------------------------------|--------------------------------------|---------------|
| | Rotura severa | Deform. severa | Rotura media | Deform. media | Deform. ligera | Grietas ligeras | Baches ligeros | Adecuada | | |
| Pésima 1 | Reconstrucción total (RECO TOT) | | Refuerzo y Fresado + Reconstrucción a mediano plazo (REF Y FR1) | Refuerzo + Reconstrucción a mediano plazo (REF1) | Microcarpeta + Refuerzo a mediano plazo (MC1) | Sello + Refuerzo a mediano plazo (Sello1) | Bacheo + Refuerzo a mediano plazo (Bach1) | Monitoreo (MONIT) | | |
| Pésima 2 | Reconstrucción parcial (RECO CA y BG) | | | | | | | | | |
| Pésima 3 | Reconstrucción superficial (RECO CA) | | | | | | | | | |
| Mala 1 | Reconstrucción total (RECO TOT) | | Refuerzo y Fresado (REF y FR) | Refuerzo (REF) | Renivelación local (RENI) | Sello con o sin calafateo (Sello) | Bacheo (Bach) | | | |
| Mala 2 | Reconstrucción parcial (RECO CA y BG) | | | | | | | | | |
| Mala 3 | Reconstrucción superficial (RECO CA) | | | | | | | | | |
| Regular | Refuerzo y fresado (REF y FR) | Refuerzo (REF) | Microcarpeta y fresado (MC y FR) | Microcarpeta (MC) | | | | Renivelación local (RENI) | Sello con o sin calafateo (Sello) | Bacheo (Bach) |
| Riesgo | Microcarpeta y fresado (MC y FR) | Microcarpeta (MC) | | | | | | | | |
| Adecuada | fresado (MC y FR) | | | | | | | Nada | | |

Vale la pena recordar que las categorías 1, 2 y 3 en las condiciones de rigidez pésima y mala, identifican si las deficiencias afectan toda la estructura, las dos capas superiores o la capa más superficial. Así mismo, la categoría 1 en las intervenciones indica que la medida recomendada soluciona los problemas temporalmente, pero se requiere otra medida a mediano plazo.

Se recomiendan acciones de reconstrucción cuando existen simultáneamente deterioro severo y condiciones de rigidez pésima a mala; las acciones de refuerzo se plantean para las combinaciones intermedias de rigidez y deterioro y las restauraciones e intervenciones locales, para combinaciones de menor deterioro y rigidez poco comprometida. Adicionalmente, se incluye el monitoreo como medida de control, en aquellos casos donde aún no se manifiesta deterioro pero los indicadores de rigidez reflejan alguna deficiencia.

Finalmente, el SID_{Soluciones} se evaluó introduciendo las calificaciones obtenidas en el SID_{Rigidez} y en el SID_{Deterioros} del caso de estudio que se ha venido analizando. Para cada par de datos introducido se obtuvieron los valores numéricos con la calificación integral del pavimento y los correspondientes términos lingüísticos asociados a las soluciones.

Al igual que en los SIDs anteriores, los resultados se validaron mediante la comparación punto a punto con las condiciones que exhibe el pavimento. Se encontró que en todos los casos las calificaciones del SID_{Deterioro} reflejan claramente los criterios y consideraciones asumidos en esta investigación para la formulación de intervenciones.

Para el tramo de tres kilómetros de carretera tomado como ejemplo, se obtuvieron las calificaciones mostradas en la Tabla 5.19, en la cual se incluyen las características de las

variables de entrada al SID. En la Figura 5.22 se muestran algunos ejemplos de las calificaciones obtenidas para este tramo, con sus respectivas intervenciones asociadas.

Tabla 5.19 Condición estructural integral y soluciones – SIDSolución

| ABSCISA (km) | RIGIDEZ | | DETERIORO | | CALIFICACIÓN ESTRUCTURAL | INTERVENCIÓN |
|--------------|---------|----------|-----------|------------------------------|--------------------------|---------------|
| 119.1 | 8.2 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 119.2 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna |
| 119.3 | 9.6 | | 9.7 | | 95 | |
| 119.4 | 9.4 | | 9.7 | | 92 | Ninguna-Monit |
| 119.5 | 9.0 | Riesgo | 9.7 | | 90 | Monitoreo |
| 119.6 | 8.1 | Regular | 9.7 | | 90 | |
| 119.7 | 8.0 | Regular | 8.6 | Deform ligera | 75 | Renivelación |
| 119.8 | 4.0 | Mala 1 | 7.0 | Deformación media-severa | 35 | Refuerzo |
| 119.9 | 7.8 | Regular | 6.4 | Rotura media, deform. ligera | 38 | |
| 120.0 | 8.0 | | 2.5 | 52 | MC y FR | |
| 120.1 | 8.0 | | 2.6 | | | |
| 120.2 | 4.0 | Mala 1 | 3.0 | Grietas ligeras | 79 | Sello1 |
| 120.3 | 8.0 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 120.4 | 3.8 | Mala 1 | 9.7 | | 90 | |
| 120.5 | 4.0 | | 9.7 | | 90 | |
| 120.6 | 8.2 | Regular | 9.7 | | 90 | |
| 120.7 | 7.9 | | 9.7 | | 90 | |
| 120.8 | 8.0 | | 9.7 | | 90 | |
| 120.9 | 7.7 | | 9.7 | | 90 | |
| 121.0 | 0.4 | Pésima1 | 9.1 | | 90 | |
| 121.1 | 4.0 | Mala 1 | 7.8 | | Def lig-media | |
| 121.2 | 0.3 | Pésima1 | 7.7 | 43 | | |
| 121.3 | 4.6 | Mala 1 | 8.4 | Def. ligera | 45 | |
| 121.4 | 7.8 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 121.5 | 4.0 | Mala 1 | 9.7 | | 90 | |
| 121.6 | 9.6 | Adecuada | 9.1 | | 93 | Monit-ninguna |
| 121.7 | 4.0 | Mala 1 | 9.7 | | 90 | Monitoreo |
| 121.8 | 9.0 | Riesgo | 9.7 | | 90 | |
| 121.9 | 4.9 | Mala 2 | 9.7 | | 90 | |
| 122.0 | 8.7 | Regular | 9.7 | 90 | | |

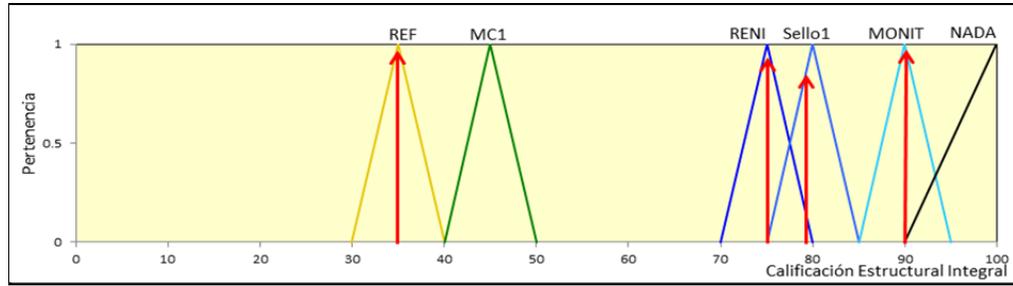


Figura 5.22 Calificaciones e intervenciones en el ejemplo de 3 km

La mayor acción en este tramo, es el refuerzo requerido entre el K119.8 y K120 (calificación de 35 a 38). La medida es consistente con la condición que exhibe el pavimento, pues en este sitio existe deformación media-severa y la rigidez es regular a mala1 (baja capacidad interna). También puede apreciarse en la Tabla 5.19 que en el tramo K121, se obtuvo una calificación de 90 donde sólo se recomienda realizar monitoreo, aunque la rigidez se clasificó como Pésima1; esta recomendación se deriva de la inexistencia de daños en el pavimento en este sitio.

Entre el K121.1 y 121.4 la calificación varía de 43 a 45 y se recomienda colocar micro-carpeta (MC1) para restaurar las deformaciones ligeras detectadas. Sin embargo, esta medida soluciona el problema de manera temporal, pues es muy probable que a mediano plazo se requiera refuerzo estructural, en virtud de las condiciones de rigidez (pésima1 a mala1). Algo similar sucede en el sub-tramo K120 a K120.3 donde se requiere la colocación de sello (calificación de 78 a 82) para solucionar los agrietamientos medios a ligeros que existen actualmente, aunque a mediano plazo se puede requerir la colocación de refuerzo.

En la Figura 5.23, se ilustran las calificaciones estructurales integrales obtenidas a lo largo del carril analizado y su relación con las categorías de condición establecidas en la Tabla 5.17. Las variaciones en estas calificaciones, claramente definen sectores con comportamiento estructural homogéneo, los cuales coinciden con aquellos identificados mediante en $SID_{Rigidez}$. Finalmente, aplicando el proceso descrito en los párrafos anteriores, se definen las necesidades de intervención para cada uno de los ocho sectores, según se ilustra en la Figura 5.24.

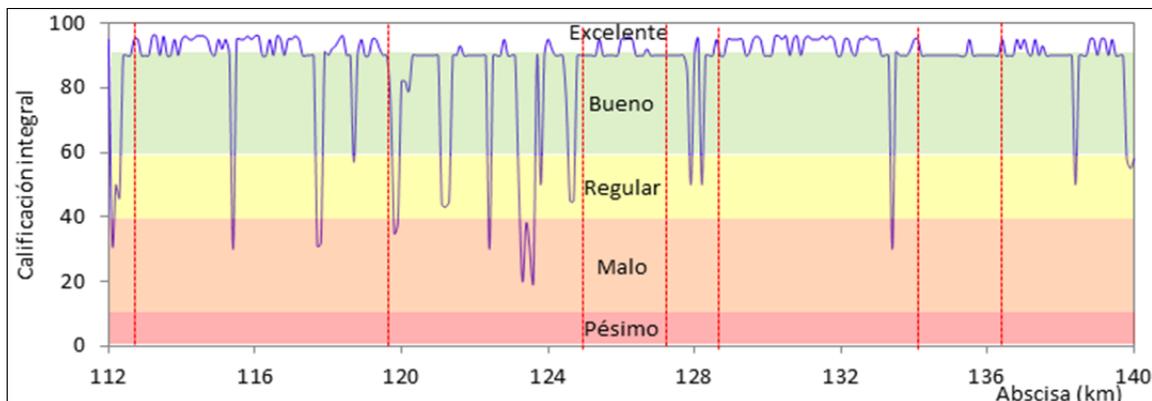


Figura 5.23 Calificación estructural integral del corredor

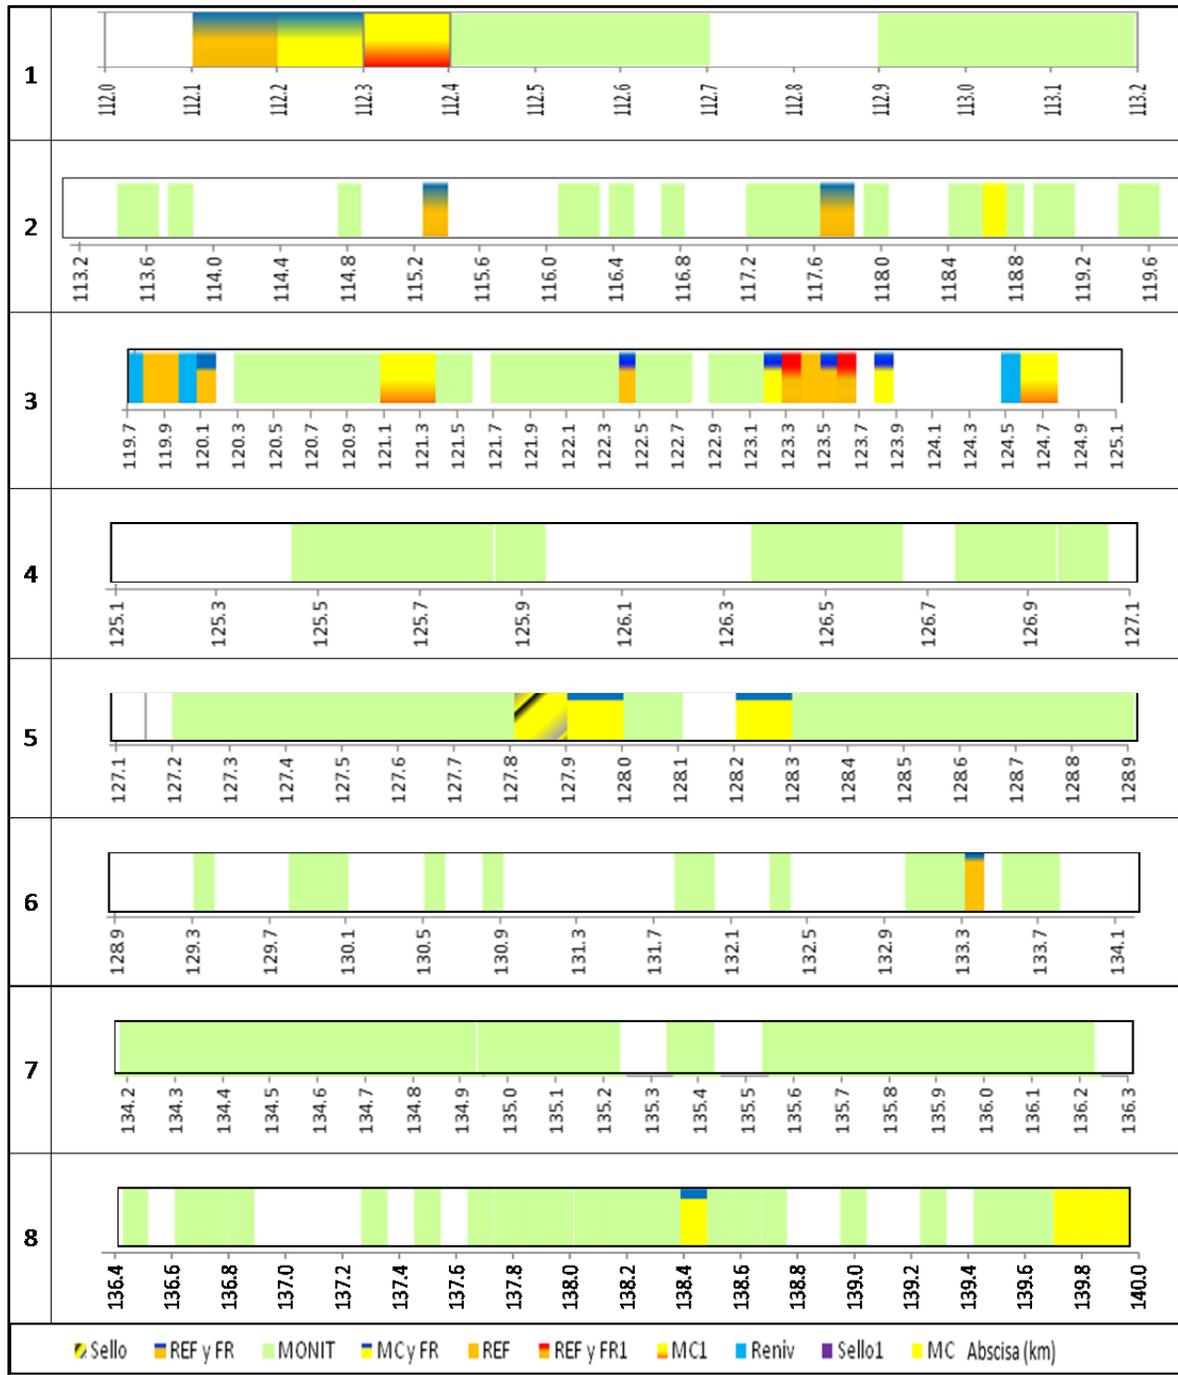


Figura 5.24 Intervenciones propuestas por sector

Todas las acciones de mantenimiento obtenidas mediante la modelación con sistemas de inferencia difusa, reflejan necesidades acordes con la condición por deterioro y por rigidez que exhibe el corredor. Sectores con daños severos a medios, ameritan intervenciones mayores y aquellos con daños ligeros requieren soluciones de restauración, a menos que la rigidez se encuentre en estado malo a pésimo.

El sector 3 (K119.7 – K125.1), requiere la mayor cantidad de acciones dadas las condiciones de rigidez y de deterioro presentes. Por el contrario, en los sectores 4, 6 y 7 no se requiere intervención alguna, salvo por prácticas de monitoreo y alguna intervención local. Posteriormente se discuten con más detalle las intervenciones a la luz de los resultados obtenidos con la modelación del deterioro hacia el futuro y de la vida remanente estimada.

El análisis de la información consignada en la Figura 5.22 y en la Figura 5.23, permite concluir que la calificación integral obtenida mediante el $SID_{\text{Soluciones}}$, puede utilizarse también de manera confiable para definir sectores homogéneos, lo cual se validó mediante el método de diferencias acumuladas.

Adicionalmente, los resultados de la modelación con los $SIDs$ diseñados, no sólo resultan útiles para tomar decisiones globales en cada sector, sino también para particularizar con el nivel de detalle que se desee, gracias a la capacidad de realizar análisis punto a punto de manera muy rápida. Se logra así, manejar racionalmente las intervenciones en función de las condiciones que realmente exhibe el corredor, integrando múltiples criterios para las decisiones finales. En el Anexo B, se presentan los resultados obtenidos mediante los tres $SIDs$ diseñados, para todo el corredor vial analizado; en el Anexo C se incluyen los tres algoritmos correspondientes desarrollados.

5.5.3 Evolución del deterioro y vida remanente

Con el ánimo de establecer en qué momento se deben aplicar las acciones de intervención propuestas, en esta investigación se plantea la aplicación de los modelos de deterioro descritos en detalle en el capítulo 3. Con ellos se busca predecir la evolución de deformaciones permanentes y del agrietamiento por fatiga en los sitios afectados actualmente. Los modelos seleccionados, se adaptaron a las siguientes condiciones particulares para el corredor:

| | |
|-------------------|--|
| CRT | Retardo en el agrietamiento por efecto de mantenimiento (3 años) |
| CDS | Calidad de la construcción de capas asfálticas (1 para contenido óptimo de asfalto) |
| COMP | Compactación relativa de base, subbase e inferiores. Se asumió 95%, considerando que la mayoría de las capas cumplen condiciones satisfactorias de compactación. |
| Sh | Velocidad de los vehículos pesados (80 km/h según la norma oficial mexicana NOM-012-SCT-2-2008) |
| HS | Espesor de la capa asfáltica medido a lo largo del corredor |
| YE4 | Número anual de ejes equivalentes calculado para las condiciones de tránsito y composición vehicular del corredor |
| Dmáx | Deflexión bajo el eje de carga, medida en las pruebas de deflexión. |
| MMP | Precipitación media mensual: 140 mm/mes (en la estación Acayucan) |
| Kcpa, Krp y Krst. | Factores de calibración (valor recomendado por defecto en el HDM4: 1) |

Aplicando el **modelo de deterioro por agrietamiento estructural** a los sitios donde se detectaron grietas medias y ligeras en el corredor analizado, se obtienen las predicciones mostradas en la Tabla 5.20 y en la Figura 5.25, para un periodo de cinco años. Teniendo en cuenta que el agrietamiento se clasificó como severo cuando sobrepasa el 20% de área afectada, es posible estimar el tiempo en el cual se alcanza la condición crítica.

Tabla 5.20 Progresión del agrietamiento

| SECTOR | SUBSECTOR | | Grietas | AÑO | | | | | V. reman (años) | |
|--------|-----------|-------|---------|-----|----|----|----|----|-----------------|-----|
| | Del Km | Al Km | | 0 | 1 | 2 | 3 | 4 | | 5 |
| 1 | 112.1 | 112.4 | Medias | 15 | 21 | 28 | 37 | 47 | 60 | 1 |
| 2 | 117.7 | 117.9 | | | | | | | | |
| 3 | 119.8 | 120.3 | Ligeras | 5 | 8 | 11 | 16 | 22 | 30 | 3.5 |
| 5 | 127.8 | 128.0 | | | | | | | | |

Se aprecia que las intervenciones planteadas en sitios afectados por agrietamiento medio, deben ser aplicadas en término de un año, mientras que la vida remanente de zonas afectadas por grietas ligeras, es del orden de 3.5 años. En caso de no realizar intervención alguna durante los siguientes cinco años, se estima que el área con grietas se incremente a 60% y 30% en los tramos afectados por grietas medias y ligeras, respectivamente.

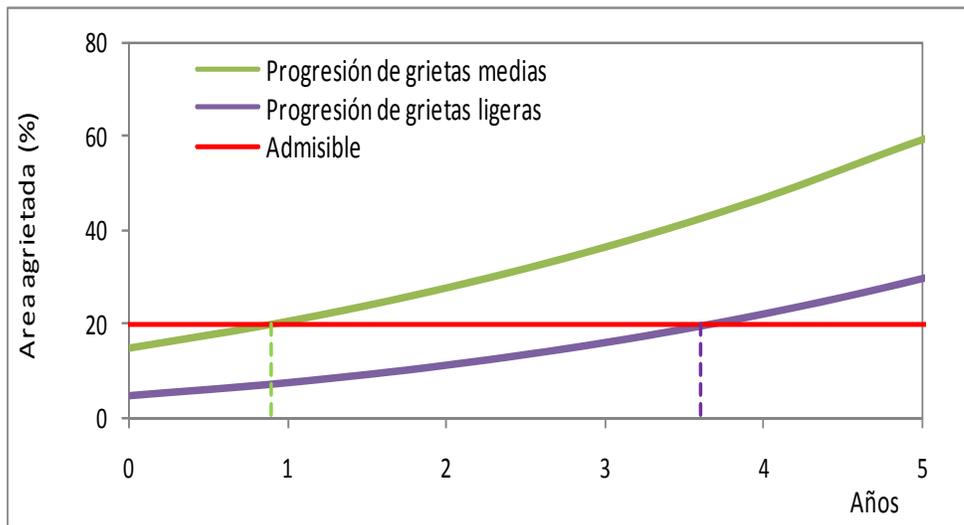


Figura 5.25 Tendencias en la evolución del agrietamiento

En cuanto a la progresión de la **deformación permanente**, se evaluaron las componentes de deformación *estructural* asociada con las capas granulares e inferiores y *plástica* atribuida a la capa asfáltica, para estimar la profundidad de roderas en un periodo de cinco años.

Aplicando los dos modelos de deformación al caso de estudio, donde sólo se detectan sitios afectados por deformaciones ligeras y medias, se obtienen los resultados mostrados en la Tabla

5.21 y en la Figura 5.26. Considerando un valor aceptable de 10 mm en la profundidad media de roderas, es posible estimar la vida remanente en función de la deformación total esperada.

Tabla 5.21 Vida remanente según la progresión de profundidad de rodera

| SECTOR | SUBSECTOR | | Dm _{máx} | YE4 Roderas | 0.70 | 0.71 | 0.72 | 0.73 | 0.74 | 0.75 | V. rem (años) |
|--------|-----------|-------|-------------------|----------------|-------|-------|-------|-------|-------|-------|------------------|
| | Del Km | Al Km | | | AÑO 0 | AÑO 1 | AÑO 2 | AÑO 3 | AÑO 4 | AÑO 5 | |
| 1 | 112.3* | 112.4 | 0.976 | Medias | 8.3 | 9.5 | 10.8 | 12.1 | 13.5 | 14.9 | 1.5 |
| 2 | 118.7 | 118.8 | 0.623 | | 6.4 | 7.7 | 9.1 | 10.4 | 11.8 | 13.2 | 3 |
| 3 | 119.7 | 119.8 | 0.667 | Ligeras | 3.9 | 6.2 | 8.5 | 10.9 | 13.3 | 15.7 | 3 |
| | 119.8* | 120.0 | 0.685 | Medias | 8.6 | 10.7 | 12.8 | 14.9 | 17.1 | 19.3 | 0.5 |
| | 120.1* | 120.2 | 0.620 | Ligeras | 3.7 | 5.8 | 7.8 | 10.0 | 12.2 | 14.4 | 3 |
| | 121.1 | 121.3 | 1.578 | | 5.5 | 8.1 | 10.7 | 13.3 | 16.0 | 18.8 | 1.5 |
| | 121.3 | 121.4 | 0.756 | | 4.4 | 6.8 | 9.2 | 11.7 | 14.2 | 16.7 | 3 |
| | 123.3 | 123.4 | 1.157 | Medias | 3.3 | 5.8 | 8.4 | 10.9 | 13.5 | 16.2 | 3 |
| | 123.4 | 123.5 | 0.943 | | 6.3 | 8.8 | 11.3 | 13.8 | 16.3 | 18.9 | 1.5 |
| | 123.5 | 123.6 | 0.990 | Ligeras | 3.5 | 6.0 | 8.5 | 11.0 | 13.6 | 16.2 | 3 |
| | 124.5 | 124.8 | 1.130 | Ligeras | 3.9 | 6.5 | 9.1 | 11.8 | 14.6 | 17.4 | 2.5 |
| 8 | 139.8 | 140.0 | 0.704 | Medias | 7.9 | 9.3 | 10.8 | 12.3 | 13.8 | 15.3 | 1.5 |

* Tramos afectados simultáneamente por grietas

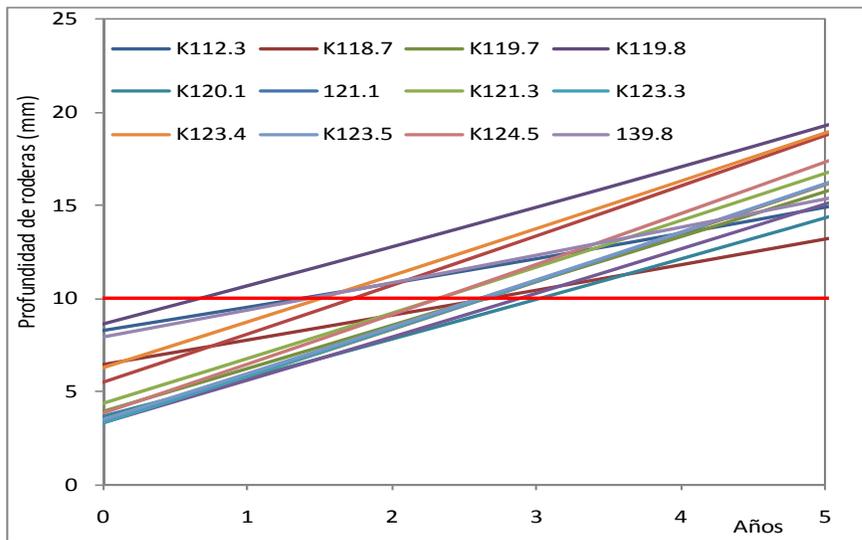


Figura 5.26 Tendencias en la evolución de la profundidad de roderas

Se puede apreciar que la progresión de la profundidad de roderas en un horizonte de cinco años, presenta variedad de tendencias que dependen de la cantidad de variables involucradas en los modelos utilizados: los niveles iniciales de deformación, el tránsito, el tipo de estructura del pavimento, la capacidad estructural dada por D_{máx}, la presencia de grietas y del espesor de la capa asfáltica, esencialmente.

Para interpretar mejor los resultados, se analizaron por separado las tendencias obtenidas en las deformaciones medias y ligeras; con ello se logró identificar algunos patrones que se repiten en diferentes sitios del corredor, según se ilustra en la Figura 5.27.

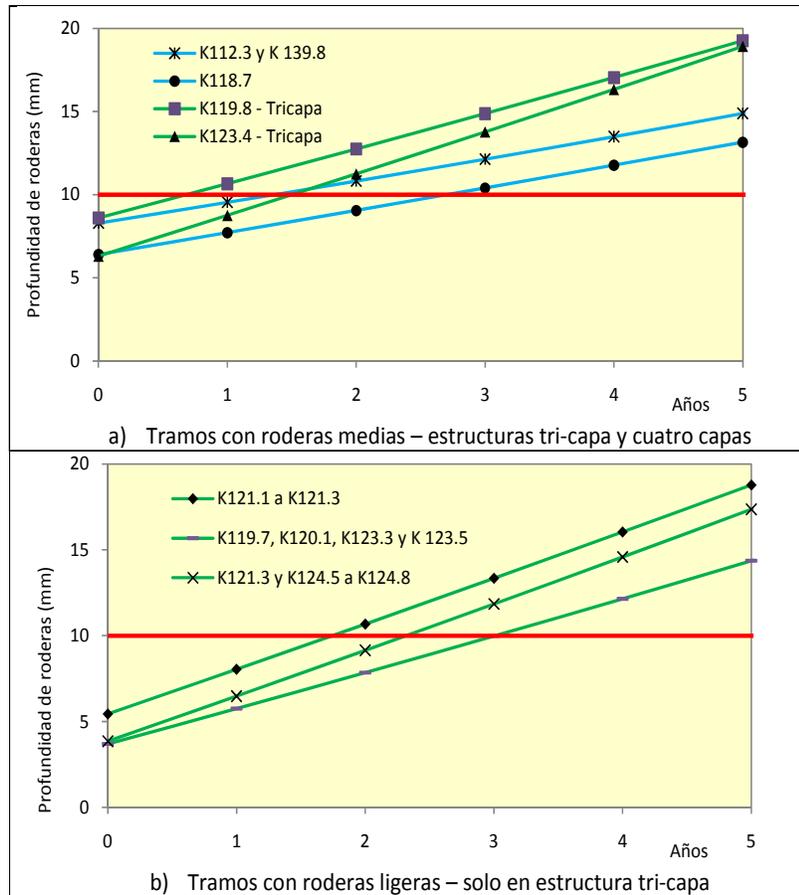


Figura 5.27 Progresión de la profundidad de roderas

En los tramos que actualmente exhiben profundidades de roderas entre 6.3 y 8.6 mm (*deformación media*), la vida remanente está entre 0.5 y 3 años. El sitio más crítico (K119.8 a K120), se ubica en la zona con estructura tricapa, exhibe el mayor valor actual de roderas de todo el corredor y se encuentra afectado por agrietamientos.

De no intervenir los tramos con deformaciones medias al cabo de 5 años, se esperarían profundidades de rodera comprendidas entre 13 y 15 mm en los sectores con estructura de cuatro capas de pavimento y entre 15 y 19 mm en la estructura tricapa. La diferencia observada en las tendencias del comportamiento deformacional entre los dos tipos de estructuras, se atribuye principalmente al mayor espesor de capa asfáltica comprometido en el proceso de deformación plástica en la zona intermedia del corredor donde existen tres capas.

De otro lado, donde existe actualmente deformaciones ligeras, se espera entre 1.5 y 3 años de vida remanente; la menor vida se espera donde $D_{m\acute{a}x}$ toma el valor de 1.578 mm, reflejo de una baja capacidad estructural.

En los tramos afectados simultáneamente por agrietamientos y por roderas, deberá optarse por aquel modelo que provea la menor vida remanente. Igualmente, debe considerarse el impacto que tendría la aplicación de las intervenciones en la progresión del deterioro. Para este estudio se aplican las siguientes hipótesis.

- La micro-carpeta, el refuerzo y la reconstrucción, corrigen grietas y roderas.
- Un sello local de grietas disminuye el área agrietada a 0%, mientras que un sello superficial con mortero asfáltico corrige grietas y roderas.
- El bacheo local disminuye el área de baches a 0%
- Las re-nivelaciones locales corrigen la profundidad de rodera a 0 mm.

En la Figura 5.28 se integran los resultados obtenidos en la modelación del deterioro para los tres sub-tramos del corredor afectados tanto por roderas como por grietas, reflejando el criterio de menor vida remanente y el impacto esperado de las intervenciones.

En el sub-tramo K112.3 a 112.4, aunque la vida remanente por ambos criterios es similar, la condición más crítica está dada por el agrietamiento (un año). Según el análisis aplicado con LD, la solución inmediata recomendable es la micro-carpeta, aunque a mediano plazo se requerirá un refuerzo estructural.

El sub-tramo K119.8 a K120 posee una vida remanente de 3.5 años según las condiciones prevalecientes de grietas ligeras, pero por deformaciones es necesario intervenir en término de un año. Mediante el $SID_{Soluciones}$, se estableció la necesidad de aplicar un refuerzo en este sitio, pues también se detectaron deficiencias desde el punto de vista de rigidez.

En el sub-tramo K120.1 a K120.2, la menor vida remanente se espera en el comportamiento de roderas, con 3 años, al cabo de los cuales se propone la colocación de un sello con mortero asfáltico, aunque a mediano plazo se requiere un refuerzo estructural.

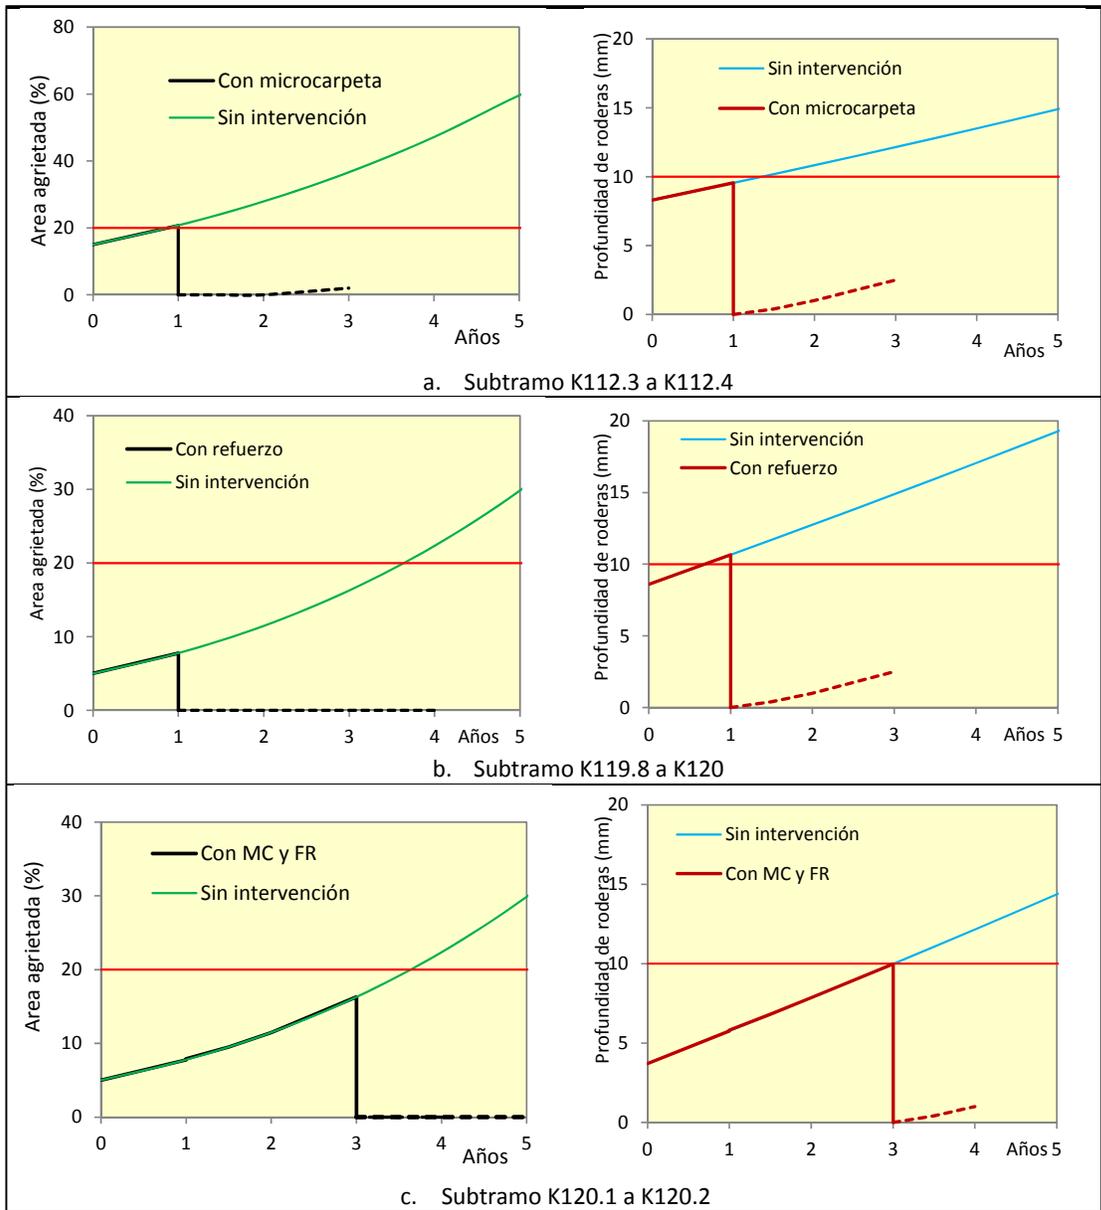


Figura 5.28 Programación de intervenciones en tramos con roderas y grietas

Como producto final de integrar los resultados obtenidos en los numerales 5.4 y 5.5, es decir la modelación con los sistemas de inferencia difusos y la predicción del deterioro, se elaboró la Tabla 5.22, donde se consolidan elementos importantes para tomar decisiones. En ella se reflejan las condiciones de rigidez, deterioro, vida remanente e intervenciones para los tramos que actualmente se encuentran afectados por algún daño.

Aunque no se modeló la evolución de los baches con el tiempo, en la Tabla 5.22 se incluyen también las recomendaciones en las zonas afectadas por este tipo de daños. Se recomienda la

reparación inmediata con bacheo localizado para evitar que el deterioro progrese, acompañado por acciones adicionales en función de los otros tipos de daño presentes.

No se evidencia la necesidad de reconstrucción inmediata en ningún sector, aunque es muy probable que los sub-tramos K123.3 - K123.4 y K123.6 - K123.7, la requieran a mediano plazo en virtud de las deficiencias de rigidez encontradas desde la capa de rodadura hasta la subbase.

Tabla 5.22 Resultados consolidados de la evaluación estructural

| Capas | Sector | Subtramo | | Rigidez | Deterioro | V. rem (años) | Intervención |
|--------|--------|-----------------|--|-----------------|--|---------------|---|
| | | Del Km | Al Km | | | | |
| Cuatro | 1 | 112.1 | 112.2 | Regular | Rot. severa-media | 1.0 | Refuerzo y fresado, previo bacheo local |
| | | 112.2 | 112.3 | Regular | Rotura media | | Microcarpeta y fresado |
| | | 112.3 | 112.4 | Regular | Deform. media Rotura media | 1.0 | Microcarpeta y refuerzo a mediano plazo* |
| | 2 | 115.4 | 115.5 | Regular | Rotura severa | 0.0 | Refuerzo y fresado, previo bacheo local |
| | | 117.7 | 117.9 | | Rotura severa | 1.0 | Refuerzo y fresado, previo bacheo local |
| | | 118.7 | 118.8 | En riesgo | Deforma. media | 3.0 | Microcarpeta |
| Tres | 3 | 119.7 | 119.8 | Regular | Deform. ligera | 3.0 | Renivelacion |
| | | 119.8 | 120.0 | Mala1 | Deform. Media | 0.5 | Refuerzo* |
| | | | | Regular | Rotura ligera | | |
| | | 120.0 | 120.1 | Regular | Rotura ligera | 3.5 | Sello |
| | | 120.1 | 120.2 | Regular | Deform. ligera | 3.0 | Microcarpeta y fresado* |
| | | | | | Rotura ligera | | |
| | | 120.2 | 120.3 | Mala1 | Rotura ligera | 3.5 | Sello; refuerzo a mediano plazo |
| | | 121.1 | 121.3 | Mala1 a pésima1 | Deforma. Ligera | 1.5 | Microcarpeta; refuerzo a mediano plazo |
| | | 121.3 | 121.4 | Mala1 | | 2.5 | Microcarpeta; refuerzo a mediano plazo |
| | | 122.4 | 122.5 | Mala 1 | Rotura media | 0.0 | Bacheo local, refuerzo y fresado |
| | | 123.2 | 123.3 | Riesgo | | | Bacheo local, microcarpeta y fresado |
| | | 123.3 | 123.4 | Pésima1 | Rotura media | 3.0 | Bacheo local inmediato; refuerzo y fresado; recons. med. plazo |
| | | 123.4 | 123.5 | Mala1 | Deform. media | 1.5 | Refuerzo |
| | | | | | Rotura media | 3.0 | Bacheo local inmediato; refuerzo y fresado |
| | | 123.6 | 123.7 | Pésima1 | Rotura media | 0.0 | Bacheo local inmediato; refuerzo y fresado; recons. med. plazo |
| 123.8 | 123.9 | Riesgo | Bacheo local inmediato; microcarpeta y fresado | | | | |
| 124.5 | 124.6 | Mala1 a pésima1 | Deform. ligera | 2.5 | Renivelacion | | |
| 124.6 | 124.8 | | | | Microcarpeta; refuerzo a mediano plazo | | |
| Cuatro | 5 | 127.8 | 127.9 | Regular | Rotura ligera | 3.5 | Sello |
| | | 127.9 | 128.0 | | Rotura media | 3.5 | Bacheo local inmediato; microcarpeta y fresado |
| | | 128.2 | 128.3 | | Rotura media | 0.0 | Bacheo local inmediato; microcarpeta y fresado |
| | 6 | 133.4 | 133.5 | Regular | Rotura severa | 0.0 | Bacheo local inmediato; refuerzo y fresado |
| | 8 | 138.4 | 138.5 | Regular | Rotura media | 0.0 | Bacheo local inmediato; microcarpeta y fresado |
| | | 139.8 | 140.0 | | Defor. Media | 1.5 | Microcarpeta |

* Tramos afectados por fenómenos de rotura y deformación simultáneamente

Para los tramos con roturas severas a medias, las acciones propuestas generalmente están acompañadas por fresado previo de la superficie para evitar el reflejo de grietas hacia el refuerzo o micro-carpeta que se coloque.

Los niveles de deformación y las deficiencias de rigidez en los tramos K119.8 a K120 y K123.4 a 123.5 sugieren la necesidad de refuerzo estructural sin fresado, aunque existan roturas ligeras; sin embargo, puede evaluarse la conveniencia de fresar al menos 3 cm y colocar la capa de refuerzo, para no alterar significativamente los niveles de rasante y la interacción con las obras de drenaje en esos tramos.

Los sectores no incluidos en la Tabla 5.22, no requieren intervención alguna en función de las condiciones actuales, aunque es necesario realizar monitoreo constante en los tramos que se indicaron en la Figura 5.24.

La vida remanente de cada uno de los tramos donde se identificaron deficiencias, es un indicador que permite decidir sobre las prioridades y oportunidades para realizar las intervenciones. Para efectos prácticos de construcción, puede resultar conveniente que aquellos tramos que requieren acciones con diferencias de ± 1 año, se intervengan al mismo tiempo quedando a juicio del administrador el adelanto o aplazamiento de las acciones en los sectores que queden cobijados por esta decisión.

Para el caso que nos ocupa, se identifican tres momentos de intervención: de inmediato, a 1 año y a 3 años, aunque en algunos tramos se espera realizar acciones a mediano plazo, en función de las condiciones globales futuras.

Finalmente, se concluye que los modelos de deterioro adaptados a las condiciones particulares del corredor, permitieron realizar pronósticos con buenos niveles de precisión y de confianza. La comparación de los comportamientos pronosticados en esta investigación, con el desempeño que exhiba el pavimento en futuras evaluaciones durante el servicio, permitiría disminuir la incertidumbre asociada con el impacto real de las intervenciones así como validar las hipótesis asumidas en la aplicación de los modelos. De igual modo, permitirían el ajuste de los factores de calibración de los modelos para obtener predicciones cada vez más ajustadas al comportamiento realmente observado, mejorando así los niveles de confianza.

5.6 Síntesis de los modelos con RNAs y SIDs propuestos

En este numeral se presenta la estructura final de las modelaciones desarrolladas y validadas en esta investigación, basadas en RNAs y LD. La Figura 5.29 integra la secuencia de cálculo propuesta para evaluar corredores viales con sistemas de pavimento de tres y cuatro capas, con estructuras convencionales o con capas de subbase rigidizada (estructuras invertidas).

Adicional a estos procesos, se debe realizar externamente la estimación de los índices BLI y MLI, a partir de las cuencas de deflexión, y la modelación del deterioro para establecer la vida remanente y el programa de intervenciones a futuro.

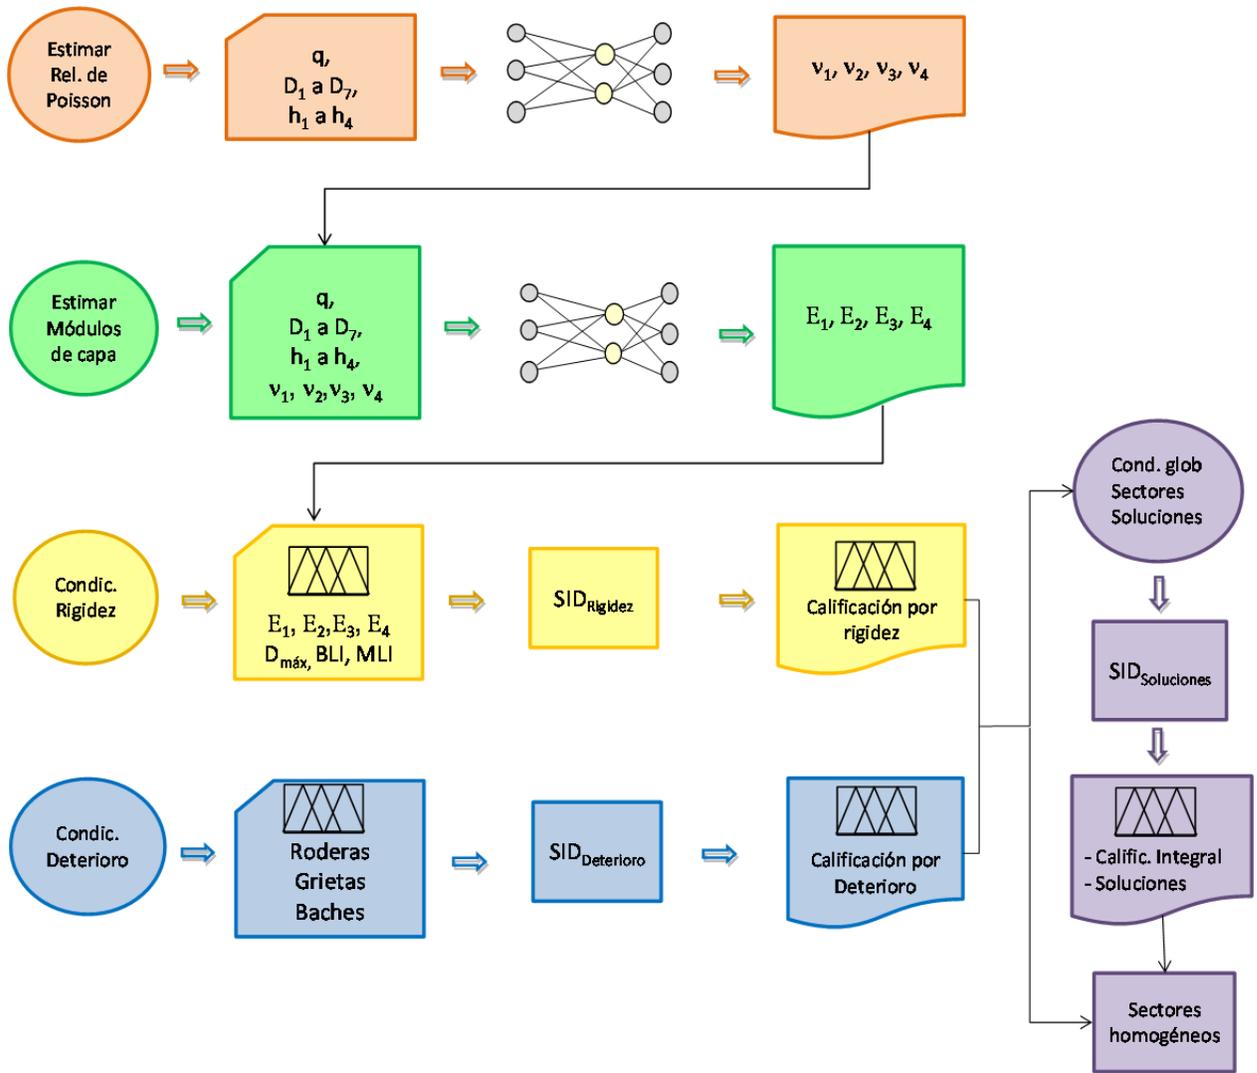


Figura 5.29 Estructura final de las modelaciones desarrolladas con RNAs y SIDs

6 CONCLUSIONES

1. Se desarrolló un Sistema de modelación no convencional para efectuar tareas asociadas con la evaluación de pavimentos en servicio y toma de decisiones de conservación. En este sistema, convergen conceptos mecánico empíricos de ingeniería de pavimentos, la experiencia y criterios de especialistas, elementos de análisis convencionales y herramientas de inteligencia artificial (RNAs y LD), lo cual quedó sintetizado en la figura 5.29.
2. El sistema de modelación planteado, aporta simplicidad, precisión (apego a la realidad) y rapidez (bajo costo computacional) y resultó suficientemente robusto para evaluar pavimentos de 3 y 4 capas, con estructuras convencionales y estructuras con sección invertida.
3. Gracias a la utilización de una base de datos que lleva implícita la mecánica propia del problema, se simularon las respuestas y el desempeño de los pavimentos, de manera muy apegada al fenómeno físico representativo. En ese sentido, se consideraron las relaciones no lineales entre múltiples variables cuantitativas y cualitativas.
4. Más allá de establecer correlaciones que reflejen buenos ajustes entre los comportamientos observados y los estimados, o de establecer ventajas y limitaciones de las modelaciones propuestas respecto a los análisis tradicionales, resulta de gran interés la forma en que el sistema desarrollado en esta investigación permitió representar la realidad de manera exitosa.
5. A la luz de los resultados obtenidos y de la experiencia lograda, se reconoce la gran capacidad de las RNAs y la LD para el procesamiento e interpretación de información y para la simulación de comportamientos, lo cual se traduce en nuevo conocimiento aplicable en la solución de problemas específicos de evaluación y de gestión de pavimentos.

A continuación se presentan las conclusiones particulares alcanzadas en los diferentes componentes del sistema de modelación.

Sobre las modelaciones neuronales para identificación de parámetros

Como producto del diseño de la RNA, se estableció una configuración de tres capas con 16 neuronas en la capa de entrada, cuatro neuronas ocultas y cuatro neuronas en la capa de salida. Como variables sensibles de entrada a la RNA, se identificaron la carga aplicada en las pruebas de deflexión, las deflexiones registradas, los espesores y las relaciones de Poisson de las capas.

Las variables identificadas como más influyentes en la determinación de módulos fueron, las deflexiones registradas en los sensores 1, 2, 3, 5, y 7, el espesor de la base granular (h_2) y el espesor (h_1) y relación de Poisson de la capa asfáltica (ν_1).

Entre 18 opciones consideradas, se identificó como red óptima para estimar módulos, la RNA con arquitectura multicapa de propagación normal hacia adelante y algoritmo de propagación rápida para el aprendizaje. Mediante esta opción se logró la convergencia a 2% de error medio absoluto después de 30 segundos y 256 iteraciones, en una computadora personal con procesador Intel Xeon 2.4 GHz.

Los módulos estimados con la RNA_{ópt} suministraron deflexiones que satisfacen simultáneamente los criterios de mínimo error, buena correlación y similitud con los valores medidos.

Para todas las capas de pavimento evaluadas, el modelo neuronal proporcionó valores de módulos dentro de intervalos más estrechos o menos dispersos que los estimados a través de la teoría elástica multicapa.

En el análisis de sensibilidad realizado con relaciones de Poisson constantes y variables para estimar módulos de capa, se observaron menores dispersiones entre las deflexiones medidas y aquellas estimadas con el conjunto de módulos bajo relaciones de Poisson variables. De esta forma, se simula más apropiadamente el comportamiento real del pavimento, se elimina la incertidumbre asociada con las suposiciones de valores constantes y se disminuye el tiempo de cómputo.

Las características del pavimento quedaron reflejadas en los módulos estimados: en la zona donde existe estructura tricapa, se obtuvieron los valores más bajos de módulos de capa asfáltica, en virtud de las altas deflexiones registradas, la presencia de una base asfáltica como parte integral de la capa superficial y la concentración de daños estructurales. En consecuencia, los bajos módulos obtenidos con RNAs indican zonas que merecen una atención especial al momento de plantear los programas de intervención.

Los resultados alcanzados permiten concluir que la RNA_{ópt} diseñada puede usarse de manera confiable para la estimación de módulos de capa en estructuras de pavimento de tres o cuatro capas.

Sobre los Sistemas de Inferencia Difusos para caracterización estructural de pavimentos

En el SID_{Rigidez}, se integraron los módulos de capa obtenidos en la modelación neuronal con los indicadores identificados como representativos de la rigidez. Mediante un análisis paramétrico realizado sobre 10 indicadores derivados de las cuencas de deflexión, se seleccionaron D_{máx}, BLI y MLI. Los tres indicadores proveen conceptos que se complementan y permitieron describir el comportamiento del pavimento con base en la forma de las cuencas; además, contribuyen a identificar las capas que presentan deficiencias estructurales.

Como resultado del SID_{Rigidez}, se estableció una calificación a lo largo del corredor, la cual permitió identificar ocho sectores homogéneos de comportamiento; estos sectores se validaron con métodos de análisis tradicionales.

A través del SID_{Soluciones}, se obtuvieron acciones de conservación que reflejan necesidades acordes con la condición por deterioro y por rigidez que exhibe el corredor. Se identificaron cuatro situaciones: sectores sin problemas, sectores que exhiben daños y deficiencias de rigidez simultáneamente, sectores afectados sólo por daños y sectores sólo con deficiencias de rigidez. Estos últimos, representan sectores que exhiben buen desempeño bajo las condiciones de tránsito actual, pero que pueden desencadenar algún deterioro en el futuro dadas las condiciones de rigidez prevalecientes.

En los sectores con deterioro severo a medio, el SID_{Soluciones} asignó calificaciones asociadas con intervenciones mayores; en aquellos con daños ligeros se plantearon soluciones de restauración, excepto donde la rigidez se caracterizó como mala a pésima. No se evidenció la necesidad de reconstrucción inmediata en ningún sector.

Gracias a la capacidad de los SIDs para realizar rápidamente análisis punto a punto, se proporcionan elementos para tomar decisiones globales en cada sector y particulares en sitios críticos. Esto contribuye a racionalizar las intervenciones y los recursos, en la práctica.

Sobre la modelación del deterioro y vida remanente

Los modelos de deterioro adaptados, permitieron predecir la vida remanente para decidir sobre la prioridad y oportunidad de las acciones. Para el corredor estudiado, se identificaron tres momentos de intervención: inmediata, a 1 año y a 3 años, con eventuales medidas definitivas a mediano plazo.

En principio, se utilizaron algunos factores de calibración que tendrán que ajustarse en la medida en que se vayan efectuando nuevas evaluaciones. De esta manera, aunque actualmente se está pronosticando el deterioro con cierto nivel de incertidumbre, se espera que el ajuste periódico o “calibración” provea modelos propios para las condiciones particulares de la carretera evaluada, con niveles de precisión y de confianza más altos.

Reflexiones finales

La integración de los métodos computacionales con la experiencia y conocimiento humano no necesariamente soluciona todos los problemas que el ingeniero de pavimentos tiene que afrontar. Es necesario estar consciente de las ventajas pero sobre todo de las limitaciones de los modelos, de modo que puedan usarse en su verdadero espacio de validez.

Las herramientas de la inteligencia artificial utilizadas en esta investigación, no constituyen por sí solas la solución global o integral a un problema complejo; normalmente deben integrarse dentro de un sistema estructurado en el contexto del problema, para desempeñar tareas específicas donde se potencien sus habilidades.

Buena parte del éxito de las modelaciones depende de la habilidad y el conocimiento de los analistas y especialistas, quienes deben realizar tareas fundamentales:

- ✓ Establecer claramente la tarea que desempeñarán los modelos
- ✓ Construcción de las bases de datos con las características específicas requeridas por las herramientas a utilizar.
- ✓ Definir los elementos necesarios para la modelación: variables de entrada y salida, la estructuración del modelo, los algoritmos y parámetros propios de cada herramienta de modelado
- ✓ Aplicar las modelaciones, probar el desempeño y la respectiva validación
- ✓ Analizar la sensibilidad de las variables utilizadas
- ✓ Interpretar los resultados
- ✓ Identificar la necesidad de ajustar o efectuar modificaciones para mejorar el desempeño
- ✓ Integrar los resultados con análisis adicionales y contextualizarlos dentro del problema global.

Lo anterior, deja claro que la aplicación de herramientas de la inteligencia artificial en problemas como los abordados en esta investigación, no tiene como fin construir modelos computacionales que simulen completamente la manera en que el cerebro humano toma decisiones y soluciona problemas. En este trabajo, las herramientas se usaron para extraer conocimiento a partir de las relaciones no lineales entre las variables representativas del problema y de los atributos que lo caracterizan, para servir de apoyo en procesos de toma de decisión.

*“Un montón de notas no es una sinfonía.
Un montón de datos no es una teoría.
Para construir una y otra,
hay que dar orden y armonía a las notas y los datos.
El secreto de la eficacia de la sinfonía y de la teoría
está en las relaciones entre sus elementos”.*

Ciencia y arte, exposición itinerante del museo Universum, 2012.

7 RECOMENDACIONES

1. Se recomienda avanzar hacia la integración de mayor variedad de sistemas de pavimento, de patrones de entrada-salida, de magnitud y severidad del deterioro y de soluciones de intervención para lograr un sistema más robusto. Al incorporar nueva información, los modelos neuronales para estimar módulos y relaciones de Poisson, tendrán la capacidad de generalizar hacia nuevos casos y asimilarlos para mejorar las predicciones mediante su característica de “plasticidad”, entendida como la habilidad de aprendizaje continuo o adaptabilidad.
2. Para lograr el panorama completo de evaluación, se recomienda extender los alcances de los sistemas diseñados hacia el componente funcional, mediante la integración del IRI, la textura superficial y la resistencia al deslizamiento, por ejemplo.
3. Después de avanzar en los dos aspectos anteriores, se estará en posibilidad de desarrollar un programa computacional para automatizar e integrar las experiencias logradas, teniendo como base el sistema de modelación propuesto en esta investigación.
4. Es recomendable realizar campañas de auscultación periódicas para comparar los comportamientos pronosticados, con el desempeño que exhibe el pavimento en el futuro bajo las condiciones reales del servicio. Estas comparaciones permitirían:
 - a) Identificar los cambios de capacidad estructural que sufre el pavimento con el tiempo y, asociarlos con las repeticiones de carga que han soportado durante el periodo analizado e incluso con cambios estacionales
 - b) Disminuir la incertidumbre asociada con el impacto real de las intervenciones
 - c) Validar las hipótesis asumidas, o en su defecto, calibrar o reformular los modelos de deterioro.

5. Finalmente, se identificaron algunas otras opciones de aplicación de herramientas de la inteligencia artificial para investigaciones futuras sobre evaluación de pavimentos:

- a) La **visión artificial o visión por computador**, así como los **análisis de imágenes** con LD, permiten automatizar y procesar información de auscultación no destructiva representada en forma de imágenes y señales donde no se muestra directamente la condición del pavimento. Estas aplicaciones pueden resultar efectivas para caracterizar la condición superficial a partir de imágenes continuas registradas mediante los equipos modernos de auscultación.
- b) Desarrollo de **Sistemas Expertos** para automatizar el conocimiento y criterios de especialistas en ingeniería de pavimentos. Estos sistemas buscan imitar la metodología empleada por los expertos para representar y solucionar problemas, mezclando usualmente técnicas de **árboles de decisión** y sistemas de reglas. Con ello no se pretende reemplazar los expertos sino tener mayor disponibilidad de su conocimiento y experiencia acumulada.
- c) **Reconocimiento de patrones con LD o RNAs** para el pre-procesamiento de información. En ocasiones resulta necesario depurar las bases de datos disponibles para evitar que la modelación de un problema se vea obstaculizada por datos atípicos o erráticos, ruido o por alguna otra deficiencia en las variables o parámetros empleados.
- d) El **agrupamiento difuso**, los **mapas auto-organizados** y el **aprendizaje no-supervisado con RNAs** tienen uso potencial para clasificar pavimentos en función de múltiples criterios y fines, como serían el tipo de estructura, la intensidad del tránsito, la edad del pavimento, los daños funcionales o estructurales, las respuestas observadas, entre otros.
- e) Los **algoritmos genéticos** por su parte, ofrecen una posibilidad para lidiar con problemas de optimización, como serían por ejemplo la toma de decisiones sobre cuándo y dónde realizar las obras de mantenimiento, cuál acción produciría la máxima eficacia general, qué beneficios se obtienen, cómo invertir de manera racional el presupuesto y cuánto tiempo se debe programar para cada actividad. En este último caso, se pueden combinar los algoritmos genéticos con **programación dinámica** para modelar la dimensión temporal.
- f) Las técnicas de **razonamiento basado en casos**, pueden utilizarse para automatizar soluciones previas exitosas de problemas y aplicarlas a casos similares, adaptadas a las condiciones particulares del nuevo problema; tal adaptación se basa en el reconocimiento de diferencias entre el problema actual y los casos previos. Estas herramientas, permiten aproximarse a buenas soluciones en la medida en que se puedan construir bases de datos con información suficientemente amplia sobre el tema.

- g) Todas estas técnicas de la inteligencia artificial se pueden combinar en **sistemas híbridos** para desarrollar aplicaciones en **realidad virtual**, que permitan simular por ejemplo las respuestas de los pavimentos ante diferentes pruebas de auscultación, condiciones ambientales, de carga, etc., mediante el ajuste de parámetros de interés.

REFERENCIAS BIBLIOGRÁFICAS

- AASHTO (1993). Guide for Design of Pavement Structures. American Association of State Highway and Transportation Officials. Washington, D.C.
- Abdallah, I.; Yuan, D.; Nazarian, S. & Ferregut, C. (2005a). Feasibility of Integrating Nondestructive Testing Data Analysis Techniques. Research Report 0-4393-1; Research Project 0-4393. Center for Transportation Infrastructure Systems, University of Texas at El Paso, TX. Texas Department of Transportation & Federal Highway Administration.
- Abdallah, I.; Yuan, D. & Nazarian, S. (2005b). Case studies on application of data Integration to Nondestructive Testing of Pavements. Research Report 0-4393-3; Research Project 0-4393. Center for Transportation Infrastructure Systems, University of Texas at El Paso, TX. Texas Department of Transportation & Federal Highway Administration.
- Abdallah, I.; Melchor-Lucero, O.; Ferregut, C; & Nazarian S. (2000). Artificial Neural Network Models for assessing Remaining Life of Flexible Pavements. Research Report 1711-2; Research Project 0-1711. Center for Highway Materials Research, University of Texas at El Paso, TX. Texas Department of Transportation.
- Abraham A, (2001). Neurofuzzy systems: State-of-the-art modeling techniques. Connectionist Models of Neurons, Learning Processes and Artificial Intelligence. Lecture Notes in Computer Science, vol 2084, pp. 269 – 276. Springer Berlin/ Heidelberg.
- Al-Khoury R., Scarpas A., Kasbergen C. y Blaauwendraad, J. (2000). Dynamic interpretation of falling weight deflectometer test results: spectral element method. Transportation Research Record 1716, pp. 49-54. Delft, Netherlands. Presentado en 79th Annual Meeting of the Transportation Research Board Washington, D.C.
- Al-Khoury R., Kasbergen C., Scarpas A., Blaauwendraad J. (2001a). Spectral element technique for efficient parameter identification of layered media Part I: Forward calculation. International Journal of Solid and Structures, 38, pp. 1605-1623.
- Al-Khoury R., Kasbergen C., Scarpas A., Blaauwendraad J. (2001b). Spectral element technique for efficient parameter identification of layered media Part II: Inverse calculation. International Journal of Solid and Structures, 38, pp. 8753-8772.
- Al-Khoury R., Kasbergen C., Scarpas A., Blaauwendraad J. (2002). Spectral element technique for efficient parameter identification of layered media Part III: Viscoelastic aspects. International Journal of Solid and Structures, 39, pp. 2189-2201.
- ARA, Inc. & ERES Consultants Division (2004). Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures. Final Report, National Cooperative Highway Research Program-NCHRP, TRB, NRC.
- Association Mondiale de la Route – World Bank (2000). Analytical Framework & Model Descriptions. HDM-4 Documentation, vol. 4. The Highway Development and Management Series.

- ASTM Designation D6433 (2003). Standard practice for roads and parking lots pavement condition index surveys. West Conshohocken, PA.
- ASTM Designation D5858 (2003). Standard Guide for Calculating *In Situ* Equivalent Elastic Moduli of Pavement Materials Using Layered Elastic Theory. West Conshohocken, PA
- ASTM Designation D4694 (2003). Standard Test Method for Deflections with a Falling-Weight-Type Impulse Load Device. West Conshohocken, PA.
- Barrantes, R., Loría, L., Sibaja, D., Porras, J. (2008). Desarrollo de herramientas de gestión con base en la determinación de índices para la Red Vial Nacional. Proyecto # UI-PI-04-08. Laboratorio Nacional de Materiales y Modelos Estructurales. San José, Costa Rica: LanammeUCR.
- Bezdek, J. (1981). Pattern Recognition with Fuzzy Objective Function Algorithms. Plenum Press, New York.
- Biswas, K. y Pellinen, T. (2007). Practical Methodology of Determining the *In Situ* Dynamic Complex Moduli for Engineering Analysis. Journal of Materials in Civil Engineering, ASCE. pp. 508 – 514.
- Burmister, D.M. (1945). The General Theory of Stresses and Displacements in Layered Systems. Journal of Applied Physics, Vol. 15, pp. 126-127, 296-302.
- Ceylan H, Guclu A, Tutumluer E, Thompson M. (2005). Backcalculation of full-depth asphalt pavement layer moduli considering nonlinear stress-dependent subgrade behavior. International Journal of Pavement Engineering; 6(3): 171-82.
- Ceylan, H., Gopalakrishnan, K. y Kim, S. (2009). Looking to the future: the next-generation hot mix asphalt dynamic modulus prediction models. International Journal of Pavement Engineering, Vol 10, No. 5, pp. 341-352.
- Collop, A., Armitage, R. y Thom, N. (2001). Assessing Variability of *In Situ* Pavement Material Stiffness Moduli. Journal of Transportation Engineering, Vol. 127, No. 1, pp. 74-81. ASCE, EBSCO publishing.
- Cordón, O., Herrera, F., Hoffmann, F. y Magdalena, L. (2001). Genetic fuzzy systems: evolutionary tuning and learning of fuzzy knowledge bases. Advances in Fuzzy Systems – Applications and Theory, vol 19. World Scientific Publishing Co. Ltd. Singapur.
- COMITRAN, Coronado J. (2000). Manual Centroamericano de Mantenimiento de Carreteras. Tomo III. Consejo Sectorial de Ministros de Transporte De Centro América.
- Consejo de Directores de Carreteras de Iberia e Iberoamérica (2002). Catálogo de Deterioro de pavimentos flexibles colección de documentos Vol. 11.
- Correa, F. (2005). Identificación de parámetros dinámicos a partir de un sistema neuro-genético. Tesis de Maestría en Ingeniería, UNAM, México, D. F.
- Crovetti, J., Shahin, M. y Touma B. (1989). Comparison of two falling weight deflectometer devices, Dynatest 8000 and KUAB 2M-FWD. Nondestructive Testing of Pavements and Backcalculation of Moduli, ASTM STP 1026, A.J. Bush III and G.Y. Baladi, Eds. ASTM, Philadelphia, pp. 59-69.
- Chang D. y Chang Ch. (1998). Dynamic interpretation for impulsive deflection test on flexible pavements. Chinese Journal of Mechanics Series A, Vol. 14 (2), pp. 91-100. Tamsui, Taiwan.

- Chatti K., Ji Y. y Harichandran R. (2004). Dynamic time domain backcalculation of layer moduli, damping, and thicknesses in flexible pavements. *Transportation Research Record* 1869, pp. 106-116. Michigan, U.S.
- Chen, D. y Scullion, T. (2008). Forensic Investigation of Roadway Pavement Failures. *Journal of Performance of Constructed Facilities*, Vol. 22, No. 1, pp. 35-44, ASCE.
- Doan, C., Liong, S. y Karunasingha, D. (1994). Derivation of effective and efficient data set with subtractive clustering method and genetic algorithm". *Journal of Hydroinformatics*, vol. 7 (4), pp. 219-233.
- Dong Q., Hachiya Y., Takahashi O., Tsubokawa Y. y Matsui K. (2002). An efficient backcalculation algorithm of time domain for large-scale pavement structures using Ritz vectors. *Finite Elements in Analysis and Design*, vol. 38, pp. 1131-1150. Elsevier Science B.V.
- Dot State of Ohio (1998). Pavement condition rating system. Report FHWA/OH-66-004. Ohio.
- Echeverry, G. (2006). Atenuación espectral sísmica en el campo lejano, una aproximación con redes neuronales artificiales". Tesis de Doctorado en Ingeniería, UNAM, México, D. F.
- Federal Highway Administration (2003). Distress identification manual for the long-term pavement performance program. Publicación No. FHWA-RD-03-031. US Department of Transportation.
- Federal Highway Administration, FHWA (2006). Geotechnical aspects of pavements. Publicación No FHWA NHI-05-037. U.S. Department of Transportation.
- Ferregut, C; Abdallah, I.; Melchor-Lucero, O y Nazarian S. (1999). Artificial Neural Network-based Methodologies for Rational Assessment of Remaining Life of Existing Pavements. Research Report 1711-1; Research Project 0-1711. Center for Highway Materials Research, University of Texas at El Paso, TX.
- García, S. (2009). Métodos Conexionistas para la Solución de Problemas de Ingeniería GeoSísmica. Tesis de Doctorado en Ingeniería, UNAM, México, D. F.
- García S., Romo M. (2005). Identificación de parámetros dinámicos con métodos analíticos y neuro-genéticos. Coloquio conmemorativo: La Ingeniería Geotécnica a 20 años de "El Sismo". Sociedad Mexicana de Mecánica de Suelos.
- García S. (2004). Determinación de las propiedades dinámicas del suelo por medio de sistemas neuro-difusos. Gacetilla No 103 del Instituto de Ingeniería UNAM.
- García S., Romo M., Taboada V., Mendoza M. (2002). Sand behavior modeling using static and dynamic artificial neural networks. Instituto de Ingeniería UNAM.
- Garnica P. y Correa A. (2004). Conceptos mecanicistas en pavimentos. Publicación técnica No. 258. SCT – IMT, Querétaro, México.
- Goel, A. & Das, A. (2008). Non-destructive Testing of Asphalt Pavements for Structural Condition Evaluation: a State of the Art. *Non Destructive Testing and Evaluation*, Vol. 23, No. 2, 121-140. Taylor & Francis Ltd.
- Goktepe A., Agar E. y Lav H. (2005). Advances in back-calculating the mechanical properties of flexible pavements. *Advances in Engineering software* 37, pp 421-431. Elsevier Ltd.
- Goktepe A., Agar E. y Lav H. (2006). Role of Learning Algorithm in Neural Network-Based Backcalculation of Flexible Pavements. *Journal of Computing in Civil Engineering*, Vol. 20, No. 5, 370-373. ASCE.

- Gómez, J., Pérez, A. y Garnica P. (2007). Evaluación estructural de pavimentos utilizando el deflectómetro de impacto HWD (Heavy Weight Deflectometer). NOTAS núm. 108, artículo 1. Instituto Mexicano del Transporte.
- Gopalakrishnan K, Thompson M. (2004). Backcalculation of airport flexible pavement non-linear moduli using artificial neural networks. Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference, 2: 652-57. Illinois.
- Gopalakrishnan, K y Ceylan, H. (2008). Stiffness characterization of full-scale airfield test pavements using computational intelligence techniques. The IES Journal Part A: Civil & Structural Engineering Vol. 1, No. 4, pp. 280–290.
- Gopalakrishnan, K. y Khaitan, K. (2010). Finite element based adaptative neuro-fuzzy inference technique for parameter identification of multilayered transportation structures. Transport, 25: 1, pp. 58 – 65.
- Haykin, S. (1999) Neural Networks, a Comprehensive Foundation. Second edition. Prentice education Inc. India.
- Heisey J., Stokoe K. y Meyer A. (1982). Moduli of pavement systems from Spectral Analysis of Surface Waves. Research Record No. 852, Transportation Research Board, Washington D. C., pp. 22-31.
- Hoffman, M. y Thompson, M. (1982). Backcalculating Nonlinear Resilient Moduli from Deflection Data. Transportation Research Record 852, pp. 42-51.
- Hoffman, M. (2003). A direct method for evaluating the structural needs of flexible pavements based on FWD deflections”. Proc. TRB 82nd annual meeting, Transportation Research Board, Washington, D.C.
- Horak E (1988). Aspects of Deflection Basin Parameters used in a mechanistic rehabilitation design procedure for flexible pavements in South Africa. PhD thesis, Department of Civil Engineering at the University of Pretoria, South Africa.
- Horak, E. y Emery, S. (2006). Falling Weight Deflectometer bowl parameters as analysis tool for pavement structural evaluations. 22nd Australian Road Research Board International Conference, Australia.
- Hu K., Jiang K. y Chang D. (2007). Study of dynamic backcalculation program with genetic algorithms for FWD on pavements. Journal of Science and Engineering Vol. 10, pp. 297-305. Tamsui, Taiwan.
- Huang Y. (1993). Pavement analysis and design. Prentice-Hall Inc., Upper Saddle River, N.J.
- IMT – SCT (1991). Catálogo de deterioro en pavimentos flexibles de carreteras mexicanas. Publicación Técnica No. 21. Querétaro, México.
- INVÍAS (2008). Guía metodológica para el diseño de obras de rehabilitación de pavimentos asfálticos de carreteras, segunda edición. Instituto Nacional de Vías, Colombia.
- Jang, JR. (1993). ANFIS: adaptative-network-based fuzzy inference system. IEEE Transactions on Systems, Man and Cybernetics, vol. 23 (3), pp. 665-685.
- Ketcham S. (1993). Dynamic response measurements and identification analysis of a pavement during falling-weight deflectometer experiments. Transportation Research Record 1415, pp. 78-87. U.S. Army, Hanover, U.S.

- Kim Y. Lee, Y. y Ranjithan S. (1998). Dynamic analysis-based approach to determine flexible pavement layer moduli using deflection basin parameters. Transportation Research Record 1639, pp. 36-42. Taiwan.
- Kim, YR., Xu, B., Kim, Y. (2000). A new backcalculation procedure based on dispersion analysis of FWD time history deflections and surface wave measurements using ANNs. NDT of pavements and backcalculation of moduli. Special Technical Publication 1375, 3: 297-312. ASTM Publications.
- Laboratorio Central de Puentes y Carreteras - LCPC (1991). VIZIR, Méthode assistée par ordinateur pour l'estimation des besoins de entretien d'un réseau routier. Paris, Francia.
- LDC Inc. - Logical Designs Consulting Inc (1996). ThinksPro Neural Networks for Windows User's Guide.
- Ledesma, A. (1987). Identificación de parámetros en geotecnia. Tesis de doctorado en ingeniería, Universidad Politécnica de Cataluña. Barcelona, España.
- Lee Y, Kim Y, Ranjithan S. (1998). Dynamic analysis-based approach to determine flexible pavement layer moduli using deflection basin parameters. Transportation Research Record 1639, pp. 36-42. Taiwan.
- Lin, Ch. & Lee, G. (1996). Neural Fuzzy Systems. A Neuro-Fuzzy Synergism to Intelligence Systems. Prentice Hall PTR, New Jersey.
- Loizos A., Boukovalas G. y Karlaftis A. (2003). Dynamic stiffness modulus for pavement subgrade evaluation. International Journal of Pavement Engineering, Vol 6, pp.5 - 15
- Loizos A. y Boukovalas G. (2005). Pavement soil characterization using a dynamic stiffness model. International Journal of Pavement Engineering, Vol 6, pp.5 – 15.
- Loizos A.; Karlaftis A. y Karlaftis M. (2007). An approach for optimizing pavement design – redesign parameters in PPP projects. Structure and Infrastructure Engineering, Vol 3, No. 3, pp. 257 – 265, Taylor & Francis.
- Lytton R. (1989). Backcalculation of pavement layer properties. STP 1026. Non destructive testing of pavement and backcalculation of moduli, pp. 7 – 38. ASTM, Philadelphia.
- Mamdani, E. H. and Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. Int. J. Man-machine Studies, Vol. 7, pág. 1-13.
- Matsui K., Nishizawa T. y Kikuta Y. (1998). Time domain backcalculation of pavement. Proceedings of SPIE - The International Society for Optical Engineering, Vol 3400, pp. 410-419. Saitama, Japón.
- Mehta Y, Roque R. (2003). Evaluation of FWD data for determination of layer moduli of pavements. Journal of Materials in Civil Engineering, ASCE; p. 25-31.
- Meier R. y Rix G. (1994). Backcalculation of flexible pavement moduli using artificial neural networks. Transportation Research Record 1448, pp. 75-82, TRB. National Research Council, Washington DC.
- Meier R. y Rix G. (1995) Back-calculation of flexible pavement moduli from dynamic deflection basins using artificial neural networks. Transportation Research Record 1473, pp. 72-81. TRB. National Research Council, Washington, D.C.

- Miller J. y Bellinger W. (2003). Distress Identification Manual for the Long-Term Pavement Performance Program LTPP. Publicación No. FHWA-RD-03-031. McLean VA.
- Ming, L., Chao, L., Hai-rui, M. y Jun-Min. (2009). Review of the Back-propagation neural network method as a basis for pavement performance assessment. Selected papers from the 2009 GeoHunan international conference. Geotechnical Special Publication No. 195, ASCE, pp. 1-8.
- Nazarian S. y Stokoe K. (1983a). Evaluation of Moduli and thicknesses of pavement systems by Spectral Analysis of Surface Waves method. Report No. 256-4, Center for Transportation Research, The University of Texas at Austin.
- Nazarian S., Stokoe K. y Hudson W. (1983b). Use of Spectral Analysis of Surface Waves method for determination of moduli and thicknesses of pavement systems. Research Record 945, Transportation Research Board, Washington D. C., pp. 38-45.
- Nazarian S. (1984a). *In situ* determination of elastic moduli of soil deposits and pavement systems by Spectral Analysis of Surface Waves method. PhD dissertation, University of Texas at Austin.
- Nazarian S. y Stokoe K. (1984b). Nondestructive testing of pavements using Surface Waves. Research Record 993, Transportation Research Board, Washington D. C., pp. 67-79.
- Nazarian S. y Stokoe K. (1986). *In situ* determination of elastic moduli of pavement systems by Spectral Analysis of Surface Waves method, theoretical aspects. Research Report 437-2, Center for Transportation Research, The University of Texas at Austin.
- Nii O y Attoh-Okine (1999). Analysis of learning rate and momentum term in backpropagation neural network algorithm trained to predict pavement performance. Advances in engineering software 30, pp 291-302.
- Orozco, R. (2005). Evaluación de pavimentos flexibles con métodos no destructivos. Tesis de Doctorado en Ingeniería, UNAM, México, D.F.
- Owusu-Aabio, S. (1998). Effect of neural network topology on flexible pavement cracking prediction. Computer Aided Civil Infrastructure Engineering, 13, pp. 349-355.
- Paterson W. (1987). Road deterioration and maintenance effects, models for planning and management. The World Bank. Washington, USA.
- Pekcan O., Tutumluer E. y Thompson M. (2008). Nondestructive pavement evaluation using ILLI-PAVE based artificial neural network models. Research Report FHWA-ICT-08-022, a report of the findings of ICT-R39. Illinois Center for Transportation, Series No. 08-022. UILU-ENG-2008-2009.
- Pellinen, T. (2001). Investigation of the use of dynamic modulus as an indicator of hot-mix asphalt performance. PhD Thesis at Arizona State University. US.
- Pérez A., Garnica P., Gómez J. y Martínez G. (2004). Uso y calibración de deflectómetros de impacto en la evaluación estructural de pavimentos. SCT – IMT, Publicación Técnica No 252. Sanfandila, Qro,
- Rakesh N., Jain A., Reddy M. y Reddy K. (2006). Artificial neural networks - genetic algorithm based model for back-calculation of pavement layer moduli. International Journal of Pavement Engineering Vol. 7(3), pp. 221-230, Taylor & Francis.

- Rangel J. (2002). Diseño del soporte y del procedimiento constructivo de túneles en macizos rocosos utilizando sistemas neuro-difusos. Tesis de Doctorado en Ingeniería, UNAM, México, D.F.
- Reddy, M.; Sudhakar, R. & Pandey, B. (2004). Selection of Genetic Algorithm Parameters for Back-calculation of Pavement Moduli. The international Journal of Pavement Engineering, vol. 5 (2), 81-90. Taylor & Francis Ltd., E & FN Spon Ltd.
- Refenes A., Zapranis A y Francis G (1994). Stock performance modeling using neural networks. A comparative with regression models. Neural Networks vol. 7 (2), pp. 375 – 388.
- Rico A., Orozco J., Téllez R. y Pérez A. (1990). Primera fase sistema Mexicano para la administración de los pavimentos (SIMAP). Documento Técnico No. 3. IMT – SCT, Sanfandila, Querétaro.
- Rico A., Téllez R. y Garnica P. (1998). Pavimentos Flexibles. Problemática, metodologías de diseño y tendencias. Publicación Técnica No 104. SCT – IMT, Querétaro.
- Rico A., Orozco J., Téllez R., Damián S., Pérez A., López D., Solorio R. y Sánchez M. (2002). Sistema de Evaluación de Pavimentos. Publicación Técnica No. 208. IMT – SCT, Sanfandila, Querétaro.
- Roeset J., Kausel E. , Cuellar V., Monte J. y Valerio J. (1994). Impact of weight falling on to the ground. J. Geotechnical Engineering, 120, pp. 53 -63.
- Rojas E. (2005). Estimación de la velocidad de ondas de corte a partir de la resistencia a la penetración estándar mediante el uso de redes neuronales. Tesis de Maestría en Ingeniería, UNAM, México, D. F.
- Romo M. P y Orozco-Santoyo R. (1990). Rigidización de sub-bases. Un nuevo enfoque en el diseño de pavimentos flexibles, XV Reunión Nacional de Mecánica de Suelos, San Luis Potosí, SLP.
- Romo M. y García S. (2006). Prediction of liquefaction-induced lateral spread: a neuro-fuzzy procedure. Publicación BB19, Investigación y Desarrollo, Instituto de Ingeniería, UNAM.
- Roque R., Romero P. y Hiltunen D. (1997). The use of linear elastic analysis to predict non linear response of pavements. Proc. 7th conference on Asphalt Pavements., pp. 1 – 13
- Sandra A., Vinayaca V., Raju K. y Sarkar A. (2007). Prioritization of pavement stretches using fuzzy MCDM approach – a case of study. Soft Computing in Industrial Applications, ASC 39, pp. 265-278.
- Saltan M., Tigdemir M. y Karasahin M. (2002). Artificial neural network application for flexible pavement thickness modelling. Turkish Journal of Engineering and Environmental Sciences, Vol. 26 (3), pp. 243-248. Esparta, Turkey.
- Saltan M., Saltan S. y Şahiner A. (2006). Fuzzy logic modeling of deflection behavior against dynamic loading in flexible pavements. Construction and Building Materials, Vol. 21 (7), pp. 1406-1414. Elsevier Ltd.
- Saltan M., Sezgin H. (2006). Hybrid neural network and finite element modeling of sub-base layer material properties in flexible pavements. Material and design 28, pp 1725-1730. Elsevier Ltd.

- Saltan M., Terzi S. (2007). Modeling deflection basin using neural networks with cross-validation technique in backcalculating flexible pavement layer moduli. *Advances in Engineering software*. Elsevier Ltd.
- SCT (2008). Norma oficial mexicana, Nom-012-sct-2-2008, sobre el peso y dimensiones máximas con los que pueden circular los vehículos de autotransporte que transitan en las vías generales de comunicación de jurisdicción federal.
- SCT (2009). El Sector Carretero en México 2009; Programa Carretero 2009 situación actual y perspectivas. Secretaría de Comunicaciones y Transporte, Subsecretaría de Infraestructura, Dirección General de Desarrollo Carretero, México.
- Schwartz, Ch. (1996). Infrastructure condition forecasting using neural networks. *Proceedings of infrastructure, planning and management*, Colorado.
- Sebaaly B., Mamlouk M., Davies T. (1986). Dynamic analysis of falling weight deflectometer data. *Transportation Research Record* 1986, Pages 63-68. Arizona.
- Seed, H.B., C.K. Chan, and C.E. Lee. (1963). Resilience characteristics of subgrade soil and their relation to fatigue failures in asphalt pavements. *Proc. International Conference on the Structural Design of Asphalt Pavement*, pp. 611-636. Michigan.
- Seo, J., Kim, S., Choi, J. y Park, D. (2009). Evaluation of Layer Properties of Flexible Pavement Using a Pseudo-Sattic Analysis Procedure of Falling Weight Deflectometer. *Construction and Building Materials*, Vol. 23, pp. 3206-3213. Elsevier Ltd.
- Shahin M. Y. (2005). *Pavement management for airports, roads and parking lots*. Second edition. Springer Science+Business Media, LLC.
- Sharma S. & Das A. (2008). Back-calculation of pavement layer Moduli from Falling Weight Deflectometer Data, Using an Artificial Neural Network. *Canadian Journal of Civil Enginnering*, Vol. 35, 57 – 66.
- Stolle, D. (1991). Modelling of dynamic response of pavements to impact loading. *Computers and Geotechnics*. Vol. 11, pp. 83-94. Ontario, Canada
- Sugeno, M. y Kang GT. (1988). Structure identification of fuzzy model. *Fuzzy Sets Systems*, vol. 23, pp. 15-33.
- Sugeno, M. y Yasukawa, T. (1993). A fuzzy logic based approach to qualitative modelling. *IEEE Trans. on Fuuy Systems*, vol I(1), pp. 7-31. D. Ti& and T. D. Gedeon.
- Sundin, S. & Braban-Ledoux, C. (2001). Artificial Intelligence-Based Decision Support Technologies in Pavement Management. *Computer-Aided Civil and Infrastructure Engineering*, Vol. 16, 143-157. Blackwell publishers, Oxford, UK.
- Takagi, T. y Sugeno M. (1985). Fuzzy identification of systems and its application to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics*, vol. 15 (1), pp. 116-132.
- Tutumluer E., Meier R. (1996). Attempt at resilient modulus modeling using artificial neural networks. *Transportation Research Record* 1560, pp. 1-6. Transportation Research Board, Washington DC.
- Ullidtz, P. (1999). Analytical Procedures in NDT Pavement Evaluation. Offered for presentation at the TRB session on Structural Modelling Applications in Pavement Analysis and Design. N.F.Coetzee, Dynatest Consulting, Inc.

- Ullidtz, P. (2000). Will nonlinear backcalculation help?. En Tayabji S. *et al.* NDT of pavement and backcalculation of moduli, Vol 3. Special technical publication STP 1375. ASTM, Pennsylvania, pp. 14 – 22.
- U.S. Army Corps of Engineers, Ladd M. y Grau R. (2001). Paver asphalt surfaced airfields Pavement Condition Index – PCI. United Facilities Criteria - UFC-3-270-06. Department of Defense, U.S. Department Research and Development Center, Vicksburg, MS.
- Uzan J. Advanced backcalculation techniques (1994). En Von Quintus H, Bush A. y Baladi G. editors. NDT of pavement and backcalculation of moduli, Vol 2. Special technical publication STP 1198. ASTM, Pennsylvania, pp. 3 – 37.
- Williams, R.; Adballah, I. & Nazarian, S. (2004). Implementation of Data Fusion Techniques in Non Destructive Testing of Pavement. Research Report 0-4393-2; Research Project 0-4393. Center for Transportation Infrastructure Systems, The University of Texas at El Paso, TX. Texas Department of Transportation & Federal Highway Administration.
- Wiseman, G., Uzan, J., Hoffman, M., Ishai, I., y Livneh, M. (1977). Simple Elastic Models for Pavement Evaluation Using Measured Deflection Bowls. Proceedings Fourth International Conference – Structural Design of Asphalt Pavements. Vol. II, Michigan.
- Xu B., Ranjithan S.R. & Kim Y.R. (2002). Development of relationships between FWD deflections and asphalt pavement layer condition indicators. 81st Annual Meeting, Transportation Research Board. Washington, DC. USA.
- Yella, S.; Dougherty, M. & Gupta, N. (2006). Artificial intelligence techniques for the automatic interpretation of data from non-destructive testing. Non-destructive Testing and Condition Monitoring. Insight Vol. 48 No 1, 10 - 20.
- Zadeh L. (1965). Fuzzy sets. Information and control, vol. 8, pp. 338-353.
- Zadeh, L. (1973). Outline of a new approach to the analysis of complex systems and decision processes. IEEE Transactions on Systems, Man, and Cybernetics, Vol. 3 (1), pp. 28-44.
- Zadeh L. (1984). Making computers think like people. IEEE Spectrum, vol 8, pp 26-32.
- Zárate M. (2011). Evolución de los Pavimentos e importancia de los indicadores de su estado superficial y estructural, sexta conferencia magistral Alfonso Rico Rodríguez. México, D.F.
- Zárate M. y Lucero M. (2009). Análisis de la respuesta de pavimentos flexibles, utilizando el deflectómetro HWD. Artículo publicado en la revista técnica Asfáltica, No 19 y en las memorias del Sexto Congreso Mexicano del Asfalto. Geosol, S.A. de C.V. México.

ANEXO A: ASPECTOS HISTÓRICOS SOBRE INTELIGENCIA ARTIFICIAL

La evolución de la Inteligencia Artificial ha estado ligada estrechamente con la lógica matemática y los desarrollos en electrónica y computación, con contribuciones importantes de la filosofía, la neurociencia y la lingüística.

Si bien, el primero en plantear reglas que describen una parte del funcionamiento de la mente para obtener conclusiones racionales fue Aristóteles (384-322 a. C.), la primera máquina auto-controlada de la que se tienen conocimientos, la construyó Ctesibio de Alejandría (250 a. C.) para regular el flujo de agua; este trabajo quedó compilado en la obra antigua de Ateneo de Náucratis (hacia los años 200 d.C), traducida en 1999 por Rodríguez-Noriega.

El concepto de obtener razonamiento artificial surge en 1275, cuando Ramon Llull diseña lo que podría llamarse una máquina para realizar deducciones lógicas de manera mecánica, cuyos principios describió posteriormente en el libro *Ars magna*. Pero sólo fue hasta mediados del siglo XX en que se desarrollaron máquinas capaces de hacer uso de lógicas formales y algoritmos de solución.

En 1943 McCulloch y Pitts presentaron un primer modelo neuronal básico capaz de calcular cualquier función lógica. En 1949, Hebb presentó su “postulado de aprendizaje” basado en el cambio continuo de la conectividad entre neuronas en la medida en que un organismo aprende diferentes tareas funcionales; este postulado inspiró el desarrollo de modelos neuronales de aprendizaje y sistemas adaptativos en medios computacionales.

Turing en 1950 abrió una nueva disciplina de las ciencias de la información al publicar el artículo *Computing Machinery and Intelligence*. Allí propuso la prueba de Turing, basada en la imitación del comportamiento humano.

En 1951, Minsky y Edmons desarrollaron la primera máquina de redes neuronales para imitar un cerebro biológico, compuesta por 40 neuronas artificiales; con base en ella, se pensó posteriormente que una máquina a mayor escala podría ser capaz de razonar con millones de neuronas, diferentes sensores y tipos de retroalimentación, pero su construcción se vio imposible en la práctica.

El término inteligencia artificial lo formalizaron McCarthy, Minsky, Rochester y Shannon, en la conferencia Dartmouth en Hanover, en 1956. En ese mismo año, Rochester *et al* se basaron en el postulado de Hebb para efectuar simulación neuronal teórica mediante ordenador viendo la necesidad de añadir el concepto de inhibición para que la teoría funcionara realmente. En el mismo año, Uttley utilizó RNAs para clasificar conjuntos sencillos de patrones binarios. Por su parte, Rosenblatt (1957) introduce el concepto de perceptrón el cual tiene la habilidad no solo de aprender patrones a partir de datos sino también de reconocerlos en nueva información, creando así la capacidad de generalización.

McCarthy desarrolla en 1958 el primer lenguaje para procesamiento simbólico, conocido como LISP en el MIT. A comienzos de los años 60s Lindsay desarrolló el programa Sad Sam de lectura e

inferencia a partir de la interpretación; Quillian, por su parte, desarrolló en 1968 las redes semánticas para representar el conocimiento. En esa misma dirección, Raphael desarrolló un programa para inferir conocimiento a partir de información suministrada y Selfridge y Neisser planteaban problemas de reconocimiento de patrones mediante máquinas.

Widrow (1960) introduce el algoritmo de mínimos cuadrados (LMS por sus siglas en inglés) y propone la Adaline, donde se incorpora un parámetro llamado “sesgo” para aumentar un grado de libertad al modelo. Winograd y Cowan (1963) mostraron que al utilizar un gran número de neuronas para representar un determinado concepto, conducía a modelaciones más robustas, aplicando así el concepto de redundancia propuesto previamente por von Newman (1956). En esta misma línea, Widrow (1962) propuso un sistema neuronal con múltiples adalinas (Madaline).

La investigación y aplicación sobre los perceptrones se atenuó en la mayoría de las áreas, a partir de la publicación del libro de Minsky y Papert (1969), donde se señalan las limitaciones computacionales del perceptrón simple, las cuales se hicieron extensivas a cualquier tipo de estructuras con perceptrones.

Aunque la primera lógica de vaguedades la desarrolló Lukasiewicz hacia 1920, el término de “difuso” como tal, lo introdujo Zadeh en 1965 con la publicación del ensayo *Fuzzy Sets*. En 1971 Zadeh formaliza los elementos que generan la metodología de la lógica difusa que se utilizan actualmente; posteriormente en 1973 formula la teoría básica de los controladores difusos.

Por su parte, Mamdani y Assilian proponen en 1975, uno de los primeros sistemas de control basados en la teoría de conjuntos difusos, sintetizando un conjunto de reglas de control lingüísticas obtenidas a partir de la experiencia humana.

Durante los años 70s y comienzo de los 80s, época de estancamiento en la investigación de las redes con perceptrones, hubo un gran desarrollo hacia los mapas auto-organizados, utilizando aprendizaje competitivo para efectos de clasificación. Los trabajos de von der Malsburg (1973) y Willshaw y von der Malsburg (1976), Grossberg (1974 - 1980) y Kohonen (1982) son los más representativos de la época.

Para esa misma época, el denominado desafío japonés de la quinta generación dio un gran auge hacia los sistemas expertos, los cuales habían surgido desde mediados de los años 60s para predecir la probabilidad de una solución dependiendo de un conjunto de reglas o condiciones.

Hopfield (1982) incorporó teorías físicas en la modelación neuronal, empleando una función de energía; también describió con claridad y rigor matemático el desempeño de una red recurrente a la que dio su nombre; esta red constituyó una variación del Asociador Lineal propuesto previamente por Anderson en 1977. Cohen y Grossberg introdujeron un caso particular de la red de Hopfield, considerando el tiempo en la dinámica no-lineal de la red.

Por su parte Barto, *et al* (1983) generaron un gran interés hacia el aprendizaje reforzado, mientras Kirkpatrick *et al* (1983) aplicaban la técnica de enfriamiento simulado en problemas de optimización, la cual fue utilizada en 1985 por Ackley *et al* en el desarrollo del primer caso exitoso de redes neuronales multicapa, conocido como máquina de Boltzman. En 1986 los trabajos de Rumelhart *et al* probaron que las limitaciones del perceptrón podían superarse mediante arquitecturas multicapa con funciones no lineales de activación. Estos últimos trabajos dejaron sin fundamento las hipótesis formuladas por Minsky y Papert en 1969, e inspiró muchas de las investigaciones posteriores.

A partir de entonces, el algoritmo de retro-propagación se convirtió en el más utilizado para entrenar redes de perceptrones multicapa; como una alternativa, Broomhead y Lowe (1988) propusieron el uso de las funciones de base radial para el diseño de redes multicapa de alimentación hacia adelante.

Además de los múltiples desarrollos y aplicaciones de la lógica difusa en el campo del control, Takagi y Sugeno desarrollan en 1985 la primera aproximación para construir reglas difusas a partir de datos de entrenamiento, integrando así las experiencias logradas en el campo de las redes neuronales.

A comienzos de los años 90s, Vapnik *et al* desarrollaron la máquina de soporte vectorial, con la cual se introdujo el concepto de aprender a partir de un set finito de ejemplos, para solucionar problemas de reconocimiento de patrones, regresión lineal, entre otros. En esta década, surgen los agentes inteligentes y sus aplicaciones.

A partir de entonces los desarrollos han estado enfocados hacia mecanismos para agilizar el proceso de aprendizaje de las redes neuronales, mejorar la precisión y la eficiencia en tiempos de cómputo. Así mismo, se ha ampliado el campo de aplicación de los sistemas neuro-difusos.

REFERENCIAS DEL ANEXO A

- Ackley, D, Hinton G. y Sejnowski T. (1985). A learning algorithm for Boltzmann machines. *Cognitive Science*, 9(1), pp. 147–169, 1985.
- Anderson, J., Pellionisz, A. y Rosenfeld, E. (1990). *Neurocomputing 2*. MIT Press, Cambridge, MA.
- Arbib, M. (1995). *The handbook of brain theory and neural networks*. MIT Press, MA.
- Barto, A., Sutton, R. y Anderson, C. (1983). Neurolike adaptive elements that can solve difficult learning control problems. *IEEE Transactions on Systems, Man, and Cybernetics*, MC13, pp. 834-846.
- Bezdek, J. (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum Press, New York.
- Broomhead, D y Lowe, D. (1988) Multivariable Functional Interpolation and Adaptive Networks. *Complex Systems* 2, pp. 321- 355.
- Cohen, M y Grossberg, S. (1983). Absolute stability of global pattern formation and parallel memory storage by competitive neural networks. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 13, no. 5, pp. 815–826.
- Gallant. S.I. (1993). *Neural Network Learning and Expert Systems*. MIT Press, Cambridge, MA.
- George. J., Reeke, N. y Edelman,G.M. (1988). Real brains and artificial intelligence. In S. R. Graubard, editor. *The Artificial Intelligence Debate*. MIT Press, Cambridge, MA.
- Grossberg, S. (1974). Classical and instrumental learning by neural networks. *Progress in Theoretical Biology*, 3, pp. 51-141.
- Grossberg, S. (1976). Adaptive pattern classification and universal recoding I: parallel development and coding of neural feature detectors. *Biological Cybernetics*, 23, pp. 121-134.
- Grossberg, S. (1980). How does a brain build a cognitive code?. *Psychological Review* 87, pp. 1-51.
- Hartman, E. J., Keeler, J. D. and J. Kowalski, M. (1990). Layered neural networks with gaussian hidden units as universal approximations. *Neural Computation*, 2, pp. 210-215.
- Haykin, S. (1999) *Neural Networks, a Comprehensive Foundation*. Second edition. Prentice education Inc. India.
- Hebb, D.O. (1949). *The Organization of Behaviour*. John Wiley & Sons, New York.
- Hinton, G. y Anderson, J. (1981.) *Parallel Models of Associative Memory*. Lawrence Erlbaum Associates, Hillsdale, NJ.
- Hopfield, J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79, pp. 2554-2558.
- Hornik, K., Stinchcombe, M. y White, H. (1989). Multilayer feed-forward networks are universal approximators. *Neural Networks*, 2, pp. 359-366.
- Kirkpatrick, S., Gelatt C. y Vecchi M. (1983). Optimization by Simulated Annealing. *Science* 220 (4598): pp. 671–680.

- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43, pp. 59-69.
- Lin, Ch. & Lee, G. (1996). *Neural Fuzzy Systems. A Neuro-Fuzzy Synergism to Intelligence Systems*. Prentice Hall PTR, New Jersey
- Lippman, R. (1987). An introduction of computing with neural nets. *IEEE ASSP Magazine*, april, pp. 4-22.
- Lukasiewicz, J. (1920). O logice trójwartościowej. *Ruch filozoficzny* 5:170–171(en Polaco). Versión en Inglés: On three-valued logic, in L. Borkowski (ed.), *Selected works by Jan Lukasiewicz*, North–Holland, Amsterdam, 1970, pp. 87–88.
- Lull, R. (1305). *Ars generalis ultima (o Ars magna)*.
- Mamdani, E. H. and Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *Int. J. Man-machine Studies*, Vol. 7, pp. 1-13.
- McCarthy J., L. Minsky M., Rochester N., Shannon, C. (1955). A proposal for the Dartmouth summer research project on artificial intelligence. Dartmouth College, Harvard University, I.B.M. Corporation, Bell Telephone Laboratories.
- McCarthy, J. (1958). Programs with common sense, paper presented at the Symposium on the Mechanization of Thought Processes, National Physical Laboratory, Teddington, England.
- McCulloch, W.S. y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, pp. 115-133.
- Minsky, M. y Papert, S. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridge, MA, expanded edition 1988.
- Rodríguez-Noriega; L. (1999). Traducción de la obra *Deipnosofistas (El banquete de los eruditos) de Ateneo de Náucratis (hacia 200 a.C)*.
- Quillian, M. (1968). Semantic Memory. En Minsky, M., editor, *Semantic Information Processing*, pp. 216-270. MIT Press.
- Raphael, B. (1964). *SIR: A computer program for Semantic Information Retrieval*. PhD thesis at the MIT.
- Rochester, N., Holland, J., Haibt, L. y Duda, W. (1956). Test on a cell assembly theory of the action of the brain, using a large digital computer. *IRE Transactions on Information Theory*, IT-2, pp. 80-93
- Rosenblatt, F. (1957). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65, pp. 386-408.
- Rumelhart, D., McClelland, J. and the PDP Research Group, editors. (1986). *Parallel Distributed Processing, volume 1:Foundations*. MIT Press, Cambridge, MA.
- Rumelhart, D., McClelland, J. and the PDP Research Group editors. (1986). *Parallel Distributed Processing, volume 2: Psychological and Biological Models*. MIT Press, Cambridge, MA.
- Rumelhart, D., Hinton, G. y Williams, R. (1986). Learning representations by back-propagating errors. *Nature*, 323, pp. 533-536.
- Selfridge, O. y Neisser, U. (1960). Pattern recognition by machine. *Scientific American*, 203, pp. 60-67.
- Siegelmann, H. y Sontag, E. (1994). Analog computation via neural networks. *Theoretical Computing Science*, 131, pp. 331-360.

- Takagi, T. y Sugeno M. (1985). Fuzzy identification of systems and its application to modeling and control. *IEEE Trans. on Systems, Man and Cybernetics*, vol. 15 (1), pp. 116-132.
- Turing, A. (1950). Computing machinery and intelligence. *Mind*, 59, pp. 433-460.
- Uttley, A. (1956). A theory of the mechanism of learning based on the computation of conditional probabilities – Proc. 1st International Congress on Cybernetics, Paris.
- Vapnik, V., Golowich, S. y Smola A. (1995). Support vector method for function approximation, regression estimation and signal processing. En: Mozer M, Jordan M, Petsche T, editors. *Advances in Neuronal Information Processing Systems 9*, Cambridge MA, Mit Press: 1997, pp. 201-87.
- von der Malsburg, C. (1973). Self-organization of orientation sensitive cells in the striate cortex. *Kybernetik*, 14, pp. 85-100.
- Willshaw, D. y von der Malsburg, C. (1976). How patterned neural connexions can be set up by self-organisation. *Proc Roy Soc B*, 194, pp. 431-445.
- Widrow, B. y Hoff. (1960). M.E. Adaptive switching circuits. In 1960 IRE WESCON Convention Record, pp. 96-104, New York.
- Widrow, B. (1962). Pattern Recognition and Adaptive Control. *Proceedings of the IRE-AIEE Joint Automatic Control Conference*, pp. 19-26.
- Winograd, S. y Cowan J. (1963). *Reliable computation in the presence of noise*. The MIT Press.
- Zadeh L. (1965). Fuzzy sets. *Information and control*, vol. 8, pp. 338-353.
- Zadeh, L. (1973). Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 3 (1), pp. 28-44.

ANEXO B: RESULTADOS DE LOS SIDs PARA EL CORREDOR VIAL

| Absc. (km) | Modulos * 1000 (kg/cm2) | | | Indicadores (mm) | | | Rigidez | | Deterioro | | Eval. Integral | |
|---------------|-------------------------|------|------|------------------|------|------|----------|----------|-----------|------------|----------------|------------|
| | E1 | E2 | E3 | Dmax | BLI | MLI | Calific. | Condic. | Calific. | Condic | Calific. | Solución |
| 112.0 | 75.59 | 5.34 | 6.96 | 0.26 | 0.12 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 112.1 | 76.73 | 2.36 | 4.09 | 0.50 | 0.18 | 0.11 | 8.0 | Regular | 1.3 | Rotsev-med | 32 | REF y FRES |
| 112.2 | 79.48 | 2.46 | 3.34 | 0.69 | 0.28 | 0.17 | 8.0 | | 2.0 | Rotmed | 50 | MC y FR |
| 112.3 | 73.30 | 2.16 | 2.47 | 0.98 | 0.31 | 0.22 | 7.4 | | 1.5 | Rotmed | 46 | MC1 |
| 112.4 | 82.01 | 3.56 | 4.28 | 0.39 | 0.13 | 0.09 | 8.5 | | 9.7 | Adecuada | 90 | Monitoreo |
| 112.5 | 68.30 | 1.58 | 2.36 | 0.81 | 0.26 | 0.18 | 8.0 | | 9.7 | | 90 | |
| 112.6 | 78.10 | 2.73 | 5.10 | 0.47 | 0.13 | 0.10 | 8.0 | | 9.7 | | 90 | |
| 112.7 | 78.86 | 5.80 | 6.64 | 0.21 | 0.07 | 0.04 | 9.6 | | Adecuada | | 9.7 | 95 |
| 112.8 | 78.44 | 5.58 | 6.59 | 0.26 | 0.10 | 0.03 | 9.6 | 9.7 | 95 | | | |
| 112.9 | 77.02 | 2.11 | 3.78 | 0.56 | 0.20 | 0.14 | 8.0 | Regular | 9.7 | | 90 | Monitoreo |
| 113.0 | 77.10 | 2.60 | 3.98 | 0.37 | 0.14 | 0.09 | 8.0 | Regular | 9.7 | | 90 | Monitoreo |
| 113.1 | 80.91 | 2.88 | 3.94 | 0.47 | 0.16 | 0.12 | 8.0 | Regular | 9.7 | | 90 | Monitoreo |
| 113.2 | 79.13 | 5.50 | 6.47 | 0.23 | 0.06 | 0.03 | 9.7 | Adecuada | 9.7 | | 96 | Ninguna |
| 113.3 | 78.97 | 5.57 | 6.42 | 0.22 | 0.06 | 0.03 | 9.7 | Adecuada | 9.7 | | 96 | |
| 113.4 | 80.62 | 4.00 | 4.62 | 0.38 | 0.14 | 0.08 | 9.0 | Riesgo | 9.7 | 90 | Monitoreo | |
| 113.5 | 78.11 | 6.12 | 7.13 | 0.16 | 0.04 | 0.02 | 9.7 | Adecuada | 9.7 | 96 | Ninguna | |
| 113.6 | 74.60 | 2.59 | 3.84 | 0.47 | 0.15 | 0.11 | 8.0 | Regular | 9.7 | 90 | Monitoreo | |
| 113.7 | 47.17 | 1.08 | 5.38 | 0.14 | 0.04 | 0.00 | 9.0 | Riesgo | 9.7 | 90 | Monitoreo | |
| 113.8 | 79.89 | 4.60 | 5.19 | 0.26 | 0.07 | 0.04 | 9.6 | Adecuada | 9.7 | 95 | Ninguna | |
| 113.9 | 75.47 | 2.72 | 3.95 | 0.35 | 0.10 | 0.07 | 8.8 | Riesgo | 9.7 | 90 | Monitoreo | |
| 114.0 | 79.38 | 4.63 | 5.35 | 0.27 | 0.08 | 0.05 | 9.6 | Adecuada | 9.7 | 95 | Ninguna | |
| 114.1 | 81.26 | 4.93 | 5.34 | 0.20 | 0.04 | 0.03 | 9.7 | | 9.7 | 96 | | |
| 114.2 | 78.59 | 5.55 | 6.41 | 0.27 | 0.09 | 0.04 | 9.6 | | 9.7 | 95 | | |
| 114.3 | 80.20 | 4.95 | 5.67 | 0.26 | 0.07 | 0.04 | 9.6 | | 9.7 | 95 | | |
| 114.4 | 76.90 | 5.96 | 7.30 | 0.13 | 0.04 | 0.02 | 9.7 | | 9.7 | 96 | | |
| 114.5 | 84.34 | 4.94 | 4.61 | 0.19 | 0.04 | 0.03 | 9.7 | | 9.7 | 96 | | |
| 114.6 | 82.76 | 5.24 | 5.21 | 0.23 | 0.08 | 0.03 | 9.7 | | 9.7 | 96 | | |
| 114.7 | 85.34 | 4.50 | 4.03 | 0.37 | 0.10 | 0.06 | 9.6 | | 9.7 | 95 | | |
| 114.8 | 85.28 | 4.34 | 3.93 | 0.33 | 0.09 | 0.06 | 9.3 | | 9.7 | 91 | Monitoreo | |
| 114.9 | 84.15 | 4.22 | 4.05 | 0.39 | 0.15 | 0.08 | 9.0 | | Riesgo | 9.7 | 90 | Monitoreo |
| 115.0 | 85.29 | 4.67 | 4.19 | 0.27 | 0.06 | 0.04 | 9.6 | Adecuada | 9.7 | 95 | Ninguna | |
| 115.1 | 85.69 | 4.49 | 3.95 | 0.34 | 0.08 | 0.06 | 9.4 | | 9.7 | 92 | Monit-ning | |
| 115.2 | 83.90 | 4.96 | 4.72 | 0.23 | 0.07 | 0.04 | 9.6 | | 9.7 | 95 | Ninguna | |
| 115.3 | 84.64 | 4.15 | 3.84 | 0.42 | 0.15 | 0.10 | 8.7 | Riesgo | 9.7 | 90 | Monitoreo | |
| 115.4 | 72.37 | 2.33 | 3.18 | 0.58 | 0.24 | 0.14 | 8.0 | Regular | 0.8 | Rotsev | 30 | REF y FRES |
| 115.5 | 80.13 | 4.51 | 5.15 | 0.25 | 0.07 | 0.04 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 115.6 | 76.41 | 5.51 | 6.96 | 0.23 | 0.11 | 0.03 | 9.6 | | 9.7 | | 95 | |
| 115.7 | 78.58 | 4.97 | 5.74 | 0.37 | 0.15 | 0.05 | 9.6 | | 9.7 | | 95 | |
| 115.8 | 80.51 | 5.35 | 5.80 | 0.22 | 0.07 | 0.03 | 9.7 | | 9.7 | | 96 | |
| 115.9 | 81.10 | 5.03 | 5.37 | 0.27 | 0.09 | 0.04 | 9.6 | | 9.7 | | 95 | |
| 116.0 | 80.73 | 5.22 | 5.63 | 0.19 | 0.06 | 0.03 | 9.7 | | 9.7 | | 96 | |
| 116.1 | 78.68 | 5.55 | 6.43 | 0.21 | 0.08 | 0.02 | 9.7 | | 9.7 | | 96 | |
| 116.2 | 76.69 | 3.36 | 4.60 | 0.32 | 0.11 | 0.06 | 9.0 | Riesgo | 9.7 | 90 | Monitoreo | |
| 116.3 | 79.15 | 3.73 | 3.94 | 0.56 | 0.23 | 0.11 | 8.8 | Riesgo | 9.7 | 90 | Monitoreo | |

| Absc. (km) | Modulos * 1000 (kg/cm2) | | | Indicadores (mm) | | | Rigidez | | Deterioro | | Eval. Integral | | |
|---------------|-------------------------|------|------|------------------|-------|-------|----------|----------|-----------|--------------|----------------|------------|------------|
| | E1 | E2 | E3 | Dmax | BLI | MLI | Calific. | Condic. | Calific. | Condic. | Calific. | Solución | |
| 116.4 | 74.79 | 5.35 | 6.40 | 0.25 | 0.09 | 0.03 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna | |
| 116.5 | 75.76 | 3.29 | 3.52 | 0.43 | 0.15 | 0.10 | 8.3 | Regular | 9.7 | | 90 | Monitoreo | |
| 116.6 | 76.87 | 5.20 | 5.93 | 0.24 | 0.07 | 0.03 | 9.7 | Adecuada | 9.7 | | 96 | Ninguna | |
| 116.7 | 74.09 | 4.81 | 5.77 | 0.31 | 0.11 | 0.04 | 9.6 | | 9.7 | | 95 | | |
| 116.8 | 74.54 | 3.35 | 3.74 | 0.34 | 0.10 | 0.08 | 8.0 | Regular | 9.7 | | 90 | Monitoreo | |
| 116.9 | 75.90 | 5.26 | 6.17 | 0.33 | 0.13 | 0.05 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna | |
| 117.0 | 80.40 | 4.82 | 5.24 | 0.31 | 0.07 | 0.05 | 9.6 | | 9.7 | | 95 | | |
| 117.1 | 76.25 | 6.40 | 7.71 | 0.21 | 0.08 | 0.03 | 9.7 | | 9.7 | | 96 | | |
| 117.2 | 79.26 | 5.43 | 6.15 | 0.21 | 0.09 | 0.04 | 9.6 | | 9.7 | | 95 | | |
| 117.3 | 56.61 | 1.25 | 3.18 | 0.57 | 0.28 | 0.13 | 8.0 | Regular | 9.7 | | 90 | Monitoreo | |
| 117.4 | 75.80 | 3.53 | 4.20 | 0.49 | 0.22 | 0.09 | 8.5 | | 9.7 | | 90 | | |
| 117.5 | 71.46 | 2.54 | 3.16 | 0.68 | 0.32 | 0.16 | 8.0 | | 9.7 | | 90 | | |
| 117.6 | 78.55 | 3.01 | 3.14 | 0.54 | 0.17 | 0.10 | 8.0 | | 9.7 | 90 | | | |
| 117.7 | 60.13 | 1.08 | 2.36 | 0.76 | 0.33 | 0.19 | 8.0 | | 1.2 | Rotsev | 31 | | REF y FRES |
| 117.8 | 61.11 | 1.15 | 2.41 | 0.71 | 0.31 | 0.18 | 8.0 | | 1.3 | Rotsev | 32 | | REF y FRES |
| 117.9 | 83.05 | 4.42 | 4.20 | 0.39 | 0.12 | 0.07 | 9.2 | Adecuada | 9.7 | Adecuada | 91 | Monitoreo | |
| 118.0 | 82.19 | 4.18 | 4.03 | 0.38 | 0.13 | 0.08 | 9.0 | Riesgo | 9.7 | | 90 | | |
| 118.1 | 82.51 | 4.35 | 4.18 | 0.39 | 0.13 | 0.06 | 9.4 | Adecuada | 9.7 | | 92 | Monitoreo | |
| 118.2 | 82.94 | 4.67 | 4.49 | 0.31 | 0.11 | 0.06 | 9.5 | | 9.7 | | 93 | Ninguna | |
| 118.3 | 81.90 | 5.23 | 5.30 | 0.24 | 0.08 | 0.04 | 9.6 | | 9.7 | | 95 | Ninguna | |
| 118.4 | 80.76 | 5.54 | 5.87 | 0.20 | 0.07 | 0.03 | 9.7 | | 9.7 | | 96 | | |
| 118.5 | 83.07 | 4.38 | 4.27 | 0.40 | 0.14 | 0.10 | 9.0 | Riesgo | 9.7 | | 90 | Monitoreo | |
| 118.6 | 79.22 | 4.20 | 4.43 | 0.49 | 0.20 | 0.10 | 9.0 | | 9.7 | | 90 | | |
| 118.7 | 83.56 | 4.63 | 4.47 | 0.439 | 0.172 | 0.078 | 9.0 | 7.3 | Defmed | | 57 | MC | |
| 118.8 | 67.07 | 2.40 | 3.32 | 0.62 | 0.25 | 0.14 | 8.0 | Regular | 9.7 | | Adecuada | 90 | Monitoreo |
| 118.9 | 82.89 | 5.16 | 5.15 | 0.29 | 0.06 | 0.04 | 9.6 | Adecuada | 9.7 | | | 95 | Ninguna |
| 119.0 | 78.75 | 3.71 | 3.86 | 0.56 | 0.24 | 0.13 | 8.8 | Riesgo | 9.7 | | | 90 | Monitoreo |
| 119.1 | 71.03 | 3.24 | 4.22 | 0.49 | 0.21 | 0.09 | 8.2 | Regular | 9.7 | 90 | | Ninguna | |
| 119.2 | 75.61 | 5.63 | 7.07 | 0.31 | 0.16 | 0.05 | 9.6 | Adecuada | 9.7 | 95 | | | |
| 119.3 | 74.59 | 6.45 | 8.26 | 0.21 | 0.12 | 0.04 | 9.6 | | 9.7 | 95 | | | |
| 119.4 | 83.44 | 4.99 | 4.84 | 0.38 | 0.13 | 0.06 | 9.4 | | 9.7 | 92 | | Monit-ning | |
| 119.5 | 75.46 | 4.25 | 5.96 | 0.39 | 0.21 | 0.09 | 9.0 | | Riesgo | 9.7 | | 90 | Monitoreo |
| 119.6 | 66.52 | 3.18 | 4.12 | 0.62 | 0.27 | 0.14 | 8.1 | Regular | 9.7 | 90 | | | |
| 119.7 | 72.15 | 2.62 | 2.97 | 0.67 | 0.25 | 0.17 | 8.0 | | 8.6 | Defligera | | 75 | Reni |
| 119.8 | 16.34 | | 2.93 | 0.97 | 0.47 | 0.18 | 4.0 | Mala 1 | 7.0 | Defmedia | | 35 | Ref |
| 119.9 | 12.58 | | 4.35 | 0.69 | 0.42 | 0.16 | 7.8 | Regular | 6.4 | Def sev-med | | 38 | Ref |
| 120.0 | 21.05 | | 3.31 | 0.86 | 0.42 | 0.16 | 8.0 | | 2.5 | Rotmed-Grlig | 78 | Sello1 | |
| 120.1 | 14.79 | | 3.56 | 0.62 | 0.32 | 0.12 | 8.0 | | 2.6 | Rotmed-Grlig | 82 | Sello1 | |
| 120.2 | 18.49 | | 2.76 | 0.83 | 0.33 | 0.17 | 4.0 | Mala 1 | 3.0 | Grlig | 79 | Sello1 | |
| 120.3 | 16.24 | | 4.54 | 0.55 | 0.31 | 0.10 | 8.0 | Regular | 9.7 | Adecuada | 90 | Monitoreo | |
| 120.4 | 17.38 | | 2.72 | 1.05 | 0.44 | 0.22 | 3.8 | Mala 1 | 9.7 | | 90 | | |
| 120.5 | 17.66 | | 2.75 | 0.82 | 0.37 | 0.14 | 4.0 | | 9.7 | | 90 | | |
| 120.6 | 24.70 | | 3.21 | 0.62 | 0.27 | 0.11 | 8.2 | Regular | 9.7 | | 90 | | |
| 120.7 | 13.35 | | 3.83 | 0.69 | 0.41 | 0.09 | 7.9 | | 9.7 | | 90 | | |

| Absc. (km) | Modulos * 1000 (kg/cm2) | | | Indicadores (mm) | | | Rigidez | | Deterioro | | Eval. Integral | |
|---------------|-------------------------|----|------|------------------|------|------|----------|----------|-----------|------------|----------------|------------|
| | E1 | E2 | E3 | Dmax | BLI | MLI | Calific. | Condic. | Calific. | Condic | Calific. | Solución |
| 120.8 | 16.51 | | 3.51 | 0.62 | 0.37 | 0.11 | 8.0 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 120.9 | 23.60 | | 3.02 | 0.79 | 0.32 | 0.18 | 7.7 | | 9.7 | | 90 | |
| 121.0 | 15.73 | | 2.60 | 1.11 | 0.50 | 0.33 | 0.4 | | Pésima1 | | 9.1 | |
| 121.1 | 16.39 | | 2.68 | 0.87 | 0.42 | 0.23 | 4.0 | Mala 1 | 7.8 | Deflig-med | 44 | MC1 |
| 121.2 | 15.32 | | 2.68 | 1.58 | 0.91 | 0.30 | 0.3 | Pésima1 | 7.7 | Deflig-med | 43 | MC1 |
| 121.3 | 16.02 | | 2.70 | 0.76 | 0.37 | 0.17 | 4.6 | Mala 1 | 8.4 | Defligera | 45 | MC1 |
| 121.4 | 15.76 | | 2.76 | 0.72 | 0.37 | 0.17 | 7.8 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 121.5 | 16.35 | | 2.67 | 1.00 | 0.45 | 0.17 | 4.0 | Mala 1 | 9.7 | | 90 | |
| 121.6 | 25.89 | | 4.33 | 0.35 | 0.19 | 0.04 | 9.6 | Adecuada | 9.1 | | 93 | Monit-ning |
| 121.7 | 16.29 | | 2.66 | 0.93 | 0.40 | 0.19 | 4.0 | Mala 1 | 9.7 | | 90 | Monitoreo |
| 121.8 | 53.70 | | 4.54 | 0.59 | 0.23 | 0.10 | 9.0 | Riesgo | 9.7 | | 90 | |
| 121.9 | 14.87 | | 2.92 | 0.75 | 0.39 | 0.12 | 4.9 | Mala 2 | 9.7 | | 90 | |
| 122.0 | 24.50 | | 3.57 | 0.58 | 0.27 | 0.08 | 8.7 | Regular | 9.7 | | 90 | |
| 122.1 | 15.64 | | 2.60 | 1.44 | 0.65 | 0.35 | 0.3 | Pesima 1 | 9.7 | | 90 | |
| 122.2 | 16.92 | | 2.61 | 1.01 | 0.54 | 0.29 | 4.0 | Mala 1 | 9.7 | | 90 | |
| 122.3 | 16.45 | | 2.84 | 0.96 | 0.52 | 0.19 | 4.0 | | 9.7 | | 90 | |
| 122.4 | 17.86 | | 2.84 | 0.82 | 0.38 | 0.22 | 4.0 | | 2.0 | Rotmed | 30 | |
| 122.5 | 15.93 | | 2.63 | 1.05 | 0.46 | 0.28 | 3.8 | | 9.7 | 90 | Monitoreo | |
| 122.6 | 27.27 | | 3.12 | 0.63 | 0.24 | 0.12 | 8.1 | Regular | 9.7 | 90 | | |
| 122.7 | 29.76 | | 4.04 | 0.47 | 0.20 | 0.07 | 9.0 | Riesgo | 9.7 | 90 | | |
| 122.8 | 28.91 | | 4.22 | 0.33 | 0.16 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 122.9 | 16.26 | | 2.63 | 1.19 | 0.42 | 0.30 | 0.4 | Pésima1 | 9.7 | 90 | Monitoreo | |
| 123.0 | 12.58 | | 5.48 | 0.61 | 0.37 | 0.06 | 8.0 | Regular | 9.7 | 90 | | |
| 123.1 | 14.06 | | 3.30 | 0.81 | 0.43 | 0.09 | 5.5 | Mala 3 | 9.7 | 90 | Monitoreo | |
| 123.2 | 35.57 | | 4.45 | 0.67 | 0.32 | 0.07 | 9.0 | Riesgo | 2.0 | Rotmed | | 50 |
| 123.3 | 15.26 | | 2.69 | 1.16 | 0.60 | 0.23 | 0.4 | Pésima1 | 2.0 | Rotmed | 20 | REF y FR 1 |
| 123.4 | 15.59 | | 2.62 | 0.94 | 0.43 | 0.25 | 4.0 | Mala 1 | 7.4 | Defmed-lig | 38 | Refuerzo |
| 123.5 | 15.67 | | 2.68 | 0.99 | 0.46 | 0.19 | 4.0 | | 2.0 | Rotmed | 30 | REF y FRES |
| 123.6 | 16.15 | | 2.63 | 1.11 | 0.46 | 0.26 | 0.4 | Pésima1 | 2.0 | Rotmed | 20 | REF y FR 1 |
| 123.7 | 19.01 | | 2.80 | 0.95 | 0.42 | 0.19 | 4.0 | Mala 1 | 9.7 | Adecuada | 90 | Monitoreo |
| 123.8 | 51.36 | | 6.93 | 0.46 | 0.22 | 0.04 | 9.0 | Riesgo | 2.0 | Rotmed | 50 | MC y FR |
| 123.9 | 37.81 | | 7.95 | 0.44 | 0.25 | 0.02 | 9.0 | | 9.7 | 90 | Monitoreo | |
| 124.0 | 66.82 | | 8.45 | 0.36 | 0.17 | 0.03 | 9.6 | Adecuada | 9.7 | 95 | Ninguna | |
| 124.1 | 33.23 | | 5.15 | 0.37 | 0.17 | 0.06 | 9.4 | | 9.7 | Adecuada | 92 | Monit-ning |
| 124.2 | 51.98 | | 5.06 | 0.50 | 0.21 | 0.08 | 9.0 | 9.7 | 90 | | Monitoreo | |
| 124.3 | 67.23 | | 5.51 | 0.53 | 0.20 | 0.07 | 9.0 | Riesgo | 9.7 | | | 90 |
| 124.4 | 56.18 | | 4.82 | 0.48 | 0.18 | 0.08 | 9.0 | 9.7 | 90 | | | |
| 124.5 | 49.14 | | 4.41 | 0.67 | 0.26 | 0.13 | 9.0 | | 8.6 | Deflig | 75 | Reni |
| 124.6 | 16.52 | | 2.66 | 0.97 | 0.38 | 0.23 | 4.0 | Mala 1 | 8.9 | Deflig | 45 | MC1 |
| 124.7 | 15.83 | | 2.61 | 1.13 | 0.46 | 0.27 | 0.4 | Pésima1 | 8.6 | Deflig | 45 | MC1 |
| 124.8 | 48.62 | | 4.66 | 0.52 | 0.21 | 0.08 | 9.0 | Riesgo | 9.7 | Adecuada | 90 | Monitoreo |
| 124.9 | 20.86 | | 2.94 | 0.83 | 0.31 | 0.18 | 4.2 | Mala 1 | 9.7 | | 90 | |
| 125.0 | 19.59 | | 2.84 | 0.90 | 0.38 | 0.20 | 4.0 | | 9.7 | | 90 | |
| 125.1 | 31.03 | | 3.73 | 0.65 | 0.28 | 0.11 | 8.8 | Riesgo | 9.7 | | 90 | |

| Absc. (km) | Modulos * 1000 (kg/cm2) | | | Indicadores (mm) | | | Rigidez | | Deterioro | | Eval. Integral | | |
|---------------|-------------------------|------|------|------------------|------|------|----------|----------|-----------|----------|----------------|-----------|----|
| | E1 | E2 | E3 | Dmax | BLI | MLI | Calific. | Condic. | Calific. | Condic. | Calific. | Solución | |
| 125.2 | 60.98 | | 5.16 | 0.52 | 0.20 | 0.08 | 9.0 | Riesgo | 9.7 | Adecuada | 90 | Monitoreo | |
| 125.3 | 35.14 | | 3.98 | 0.61 | 0.28 | 0.10 | 9.0 | | 9.7 | | 90 | | |
| 125.4 | 37.22 | | 5.79 | 0.38 | 0.20 | 0.05 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna | |
| 125.5 | 21.91 | | 5.58 | 0.30 | 0.18 | 0.05 | 8.3 | Regular | 9.7 | | 90 | Monitoreo | |
| 125.6 | 44.02 | | 5.98 | 0.43 | 0.22 | 0.04 | 9.1 | Riesgo | 9.7 | | 90 | | |
| 125.7 | 33.58 | | 4.13 | 0.55 | 0.24 | 0.08 | 9.0 | | 9.7 | | 90 | | |
| 125.8 | 48.80 | | 5.08 | 0.43 | 0.18 | 0.04 | 9.1 | 9.7 | 90 | | | | |
| 125.9 | 21.81 | | 4.37 | 0.31 | 0.15 | 0.04 | 8.2 | Regular | 9.7 | | 90 | | |
| 126.0 | 62.12 | | 6.82 | 0.37 | 0.16 | 0.04 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna | |
| 126.1 | 43.83 | | 7.80 | 0.28 | 0.15 | 0.02 | 9.6 | | 9.7 | | 95 | | |
| 126.2 | 61.59 | | 9.20 | 0.24 | 0.13 | 0.02 | 9.7 | | 9.7 | 96 | | | |
| 126.3 | 64.92 | | 8.15 | 0.26 | 0.11 | 0.02 | 9.6 | | 9.7 | 95 | | | |
| 126.4 | 18.78 | | 2.98 | 0.68 | 0.30 | 0.15 | 8.0 | Regular | 9.7 | 90 | Monitoreo | | |
| 126.5 | 53.67 | | 6.10 | 0.43 | 0.19 | 0.05 | 9.1 | Regular | 9.7 | 90 | | | |
| 126.6 | 58.75 | | 4.97 | 0.48 | 0.17 | 0.09 | 9.0 | 9.7 | 90 | | | | |
| 126.7 | 66.48 | | 6.06 | 0.39 | 0.14 | 0.06 | 9.4 | Adecuada | 9.7 | 92 | Ninguna | | |
| 126.8 | 34.50 | | 3.43 | 0.64 | 0.22 | 0.13 | 8.4 | Regular | 9.7 | 90 | Monitoreo | | |
| 126.9 | 62.10 | | 5.38 | 0.51 | 0.20 | 0.08 | 9.0 | Riesgo | 9.7 | 90 | | | |
| 127.0 | 75.24 | | 6.71 | 0.47 | 0.19 | 0.06 | 9.0 | 9.7 | 90 | | | | |
| 127.1 | 77.54 | 3.10 | 5.86 | 0.41 | 0.13 | 0.08 | 8.3 | Regular | 9.7 | 90 | | | |
| 127.2 | 75.65 | 3.79 | 6.29 | 0.39 | 0.14 | 0.05 | 8.6 | Riesgo | 9.7 | 90 | | | |
| 127.3 | 75.61 | 3.26 | 5.50 | 0.46 | 0.17 | 0.08 | 8.4 | Regular | 9.7 | 90 | | | |
| 127.4 | 76.68 | 3.86 | 6.49 | 0.41 | 0.15 | 0.06 | 8.7 | Riesgo | 9.7 | 90 | | | |
| 127.5 | 74.24 | 2.20 | 4.68 | 0.62 | 0.26 | 0.11 | 8.0 | Regular | 9.7 | 90 | | | |
| 127.6 | 61.78 | 1.50 | 4.55 | 0.71 | 0.38 | 0.11 | 8.0 | | 9.7 | 90 | | | |
| 127.7 | 57.37 | 2.08 | 6.47 | 0.50 | 0.29 | 0.05 | 8.0 | | 9.7 | 90 | | | |
| 127.8 | 63.49 | 1.65 | 4.86 | 0.64 | 0.32 | 0.09 | 8.0 | | 3.0 | Grlig | 85 | Sello | |
| 127.9 | 69.63 | 2.05 | 4.99 | 0.59 | 0.29 | 0.08 | 8.0 | 2.0 | Rotmed | 50 | MC y FR | | |
| 128.0 | 77.40 | 3.45 | 5.59 | 0.45 | 0.17 | 0.08 | 8.4 | 9.7 | Adecuada | 90 | Monitoreo | | |
| 128.1 | 76.39 | 4.66 | 5.92 | 0.27 | 0.08 | 0.04 | 9.6 | Adecuada | | 9.7 | 95 | Ninguna | |
| 128.2 | 75.42 | 2.92 | 6.09 | 0.55 | 0.23 | 0.08 | 8.0 | Regular | 2.0 | Rotmed | 50 | MC y FR | |
| 128.3 | 74.59 | 3.16 | 4.53 | 0.40 | 0.16 | 0.08 | 8.3 | | 9.7 | 90 | Monitoreo | | |
| 128.4 | 76.13 | 2.47 | 5.37 | 0.60 | 0.16 | 0.13 | 8.0 | | 9.7 | 90 | | | |
| 128.5 | 66.46 | 1.90 | 4.72 | 0.48 | 0.24 | 0.09 | 8.0 | | 9.7 | 90 | | | |
| 128.6 | 78.32 | 4.70 | 5.60 | 0.29 | 0.09 | 0.06 | 9.6 | Adecuada | 9.7 | 95 | Ninguna | | |
| 128.7 | 77.91 | 3.06 | 5.54 | 0.43 | 0.14 | 0.08 | 8.1 | Regular | 9.7 | 90 | Monitoreo | | |
| 128.8 | 76.18 | 2.54 | 5.61 | 0.49 | 0.14 | 0.09 | 8.0 | | 9.7 | 90 | | | |
| 128.9 | 77.60 | 4.29 | 5.93 | 0.30 | 0.08 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna | |
| 129.0 | 78.03 | 5.11 | 6.08 | 0.28 | 0.09 | 0.04 | 9.6 | | 9.7 | | 95 | | |
| 129.1 | 78.58 | 4.75 | 6.00 | 0.27 | 0.07 | 0.04 | 9.6 | | Adecuada | | 9.7 | | 95 |
| 129.2 | 76.36 | 4.85 | 6.06 | 0.34 | 0.13 | 0.05 | 9.6 | | 9.7 | | 95 | | |
| 129.3 | 79.27 | 4.48 | 5.14 | 0.25 | 0.06 | 0.06 | 9.6 | 9.7 | 95 | | | | |
| 129.4 | 78.85 | 4.45 | 5.19 | 0.37 | 0.13 | 0.08 | 9.0 | Riesgo | 9.7 | 90 | Monitoreo | | |
| 129.5 | 75.31 | 5.22 | 6.60 | 0.36 | 0.16 | 0.06 | 9.3 | Adecuada | 9.7 | 91 | | | |

| Absc. (km) | Modulos * 1000 (kg/cm2) | | | Indicadores (mm) | | | Rigidez | | Deterioro | | Eval. Integral | |
|---------------|-------------------------|------|------|------------------|------|------|----------|----------|-----------|----------|----------------|------------|
| | E1 | E2 | E3 | Dmax | BLI | MLI | Calific. | Condic. | Calific. | Condic | Calific. | Solución |
| 129.6 | 76.07 | 4.63 | 5.81 | 0.31 | 0.12 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 129.7 | 74.14 | 5.19 | 7.15 | 0.18 | 0.07 | 0.03 | 9.7 | | 9.7 | | 96 | |
| 129.8 | 77.74 | 4.62 | 5.97 | 0.33 | 0.10 | 0.05 | 9.6 | | 9.7 | | 95 | |
| 129.9 | 75.93 | 3.24 | 4.92 | 0.41 | 0.13 | 0.08 | 8.5 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 130.0 | 77.67 | 3.05 | 5.38 | 0.42 | 0.13 | 0.08 | 8.2 | | 9.7 | | 90 | |
| 130.1 | 77.43 | 2.96 | 5.21 | 0.41 | 0.12 | 0.08 | 8.0 | | 9.7 | | 90 | |
| 130.2 | 75.17 | 5.54 | 7.19 | 0.15 | 0.06 | 0.03 | 9.7 | Adecuada | 9.7 | Adecuada | 96 | Ninguna |
| 130.3 | 77.49 | 5.24 | 6.29 | 0.17 | 0.05 | 0.03 | 9.7 | | 9.7 | | 96 | |
| 130.4 | 77.20 | 5.00 | 6.28 | 0.32 | 0.12 | 0.04 | 9.6 | | 9.7 | | 95 | |
| 130.5 | 71.67 | 5.06 | 7.52 | 0.18 | 0.09 | 0.03 | 9.7 | | 9.7 | | 96 | |
| 130.6 | 78.31 | 3.27 | 5.73 | 0.38 | 0.11 | 0.06 | 9.0 | Riesgo | 9.7 | Adecuada | 90 | Monitoreo |
| 130.7 | 80.12 | 4.78 | 5.74 | 0.30 | 0.09 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 130.8 | 75.40 | 5.92 | 7.52 | 0.18 | 0.07 | 0.02 | 9.7 | | 9.7 | | 96 | |
| 130.9 | 76.58 | 3.04 | 6.02 | 0.47 | 0.18 | 0.08 | 8.0 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 131.0 | 79.71 | 4.13 | 5.34 | 0.28 | 0.07 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 131.1 | 75.32 | 5.43 | 7.08 | 0.17 | 0.07 | 0.03 | 9.7 | | 9.7 | | 96 | |
| 131.2 | 77.71 | 5.09 | 6.75 | 0.26 | 0.08 | 0.03 | 9.6 | | 9.7 | | 95 | |
| 131.3 | 78.09 | 5.01 | 6.05 | 0.25 | 0.08 | 0.04 | 9.6 | | 9.7 | | 95 | |
| 131.4 | 79.49 | 4.44 | 5.67 | 0.32 | 0.10 | 0.06 | 9.6 | | 9.7 | | 95 | |
| 131.5 | 75.93 | 5.70 | 7.23 | 0.15 | 0.06 | 0.02 | 9.7 | | 9.7 | | 96 | |
| 131.6 | 69.74 | 4.82 | 7.88 | 0.17 | 0.10 | 0.03 | 9.6 | | 9.7 | | 95 | |
| 131.7 | 77.66 | 5.44 | 7.02 | 0.22 | 0.06 | 0.02 | 9.7 | | 9.7 | | 96 | |
| 131.8 | 79.45 | 5.32 | 5.98 | 0.33 | 0.13 | 0.04 | 9.6 | | 9.7 | | 95 | |
| 131.9 | 77.97 | 3.49 | 4.13 | 0.48 | 0.18 | 0.09 | 8.5 | Riesgo | 9.7 | Adecuada | 90 | Monitoreo |
| 132.0 | 80.95 | 4.43 | 4.74 | 0.39 | 0.13 | 0.07 | 9.0 | Riesgo | 9.7 | Adecuada | 90 | Monitoreo |
| 132.1 | 79.28 | 4.84 | 5.50 | 0.34 | 0.13 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 132.2 | 76.93 | 5.66 | 6.97 | 0.21 | 0.11 | 0.03 | 9.6 | | 9.7 | | 95 | |
| 132.3 | 78.82 | 4.66 | 5.30 | 0.38 | 0.16 | 0.06 | 9.3 | | 9.7 | | 91 | |
| 132.4 | 78.57 | 4.69 | 5.39 | 0.35 | 0.15 | 0.08 | 9.0 | Riesgo | 9.7 | Adecuada | 90 | Monitoreo |
| 132.5 | 74.62 | 4.68 | 6.54 | 0.25 | 0.12 | 0.05 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna |
| 132.6 | 78.22 | 4.96 | 5.80 | 0.33 | 0.15 | 0.05 | 9.6 | | 9.7 | | 95 | |
| 132.7 | 80.54 | 5.48 | 5.79 | 0.24 | 0.07 | 0.03 | 9.7 | | 9.7 | | 96 | |
| 132.8 | 75.03 | 6.28 | 8.02 | 0.19 | 0.11 | 0.02 | 9.6 | | 9.7 | | 95 | |
| 132.9 | 77.97 | 5.89 | 6.72 | 0.28 | 0.11 | 0.04 | 9.6 | | 9.7 | | 95 | |
| 133.0 | 80.49 | 5.06 | 5.28 | 0.34 | 0.11 | 0.05 | 9.6 | 9.7 | 95 | | | |
| 133.1 | 77.89 | 4.67 | 5.15 | 0.37 | 0.15 | 0.07 | 9.0 | Riesgo | 9.7 | Adecuada | 90 | Monitoreo |
| 133.2 | 74.39 | 4.83 | 5.90 | 0.40 | 0.20 | 0.07 | 9.0 | | 9.7 | | 90 | |
| 133.3 | 65.32 | 2.20 | 3.50 | 0.60 | 0.29 | 0.13 | 8.0 | Regular | 9.7 | Adecuada | 90 | |
| 133.4 | 43.94 | 0.64 | 2.90 | 0.59 | 0.28 | 0.12 | 8.0 | Regular | 0.8 | Rot sev | 30 | REF y FRES |
| 133.5 | 77.80 | 5.76 | 6.73 | 0.33 | 0.16 | 0.06 | 9.3 | Adecuada | 9.7 | Adecuada | 91 | Monitoreo |
| 133.6 | 81.22 | 4.21 | 4.43 | 0.37 | 0.13 | 0.08 | 9.0 | Riesgo | 9.7 | | 90 | |
| 133.7 | 42.65 | 0.58 | 3.80 | 0.27 | 0.11 | 0.05 | 8.9 | Riesgo | 9.7 | | 90 | |
| 133.8 | 81.16 | 3.97 | 4.24 | 0.36 | 0.13 | 0.08 | 8.9 | Riesgo | 9.7 | | 90 | |
| 133.9 | 77.02 | 4.80 | 6.06 | 0.29 | 0.14 | 0.06 | 9.4 | Adecuada | 9.7 | Adecuada | 92 | Monit-ning |

| Absc. (km) | Modulos * 1000 (kg/cm2) | | | Indicadores (mm) | | | Rigidez | | Deterioro | | Eval. Integral | | |
|---------------|-------------------------|------|------|------------------|------|------|----------|----------|-----------|----------|----------------|-----------|----|
| | E1 | E2 | E3 | Dmax | BLI | MLI | Calific. | Condic. | Calific. | Condic. | Calific. | Solución | |
| 134.0 | 74.36 | 5.42 | 7.23 | 0.23 | 0.11 | 0.04 | 9.6 | Adecuada | 9.7 | Adecuada | 95 | Ninguna | |
| 134.1 | 76.11 | 6.09 | 7.52 | 0.22 | 0.10 | 0.02 | 9.6 | | 9.7 | | 95 | | |
| 134.2 | 47.23 | 0.43 | 3.05 | 0.71 | 0.34 | 0.18 | 8.0 | Regular | 9.7 | | 90 | Monitoreo | |
| 134.3 | 70.71 | 3.38 | 5.18 | 0.36 | 0.16 | 0.08 | 8.5 | | 9.7 | | 90 | | |
| 134.4 | 55.67 | 0.75 | 2.77 | 0.63 | 0.26 | 0.18 | 8.0 | | 9.7 | | 90 | | |
| 134.5 | 46.54 | 1.04 | 4.09 | 0.43 | 0.21 | 0.10 | 8.0 | | 9.7 | | 90 | | |
| 134.6 | 55.56 | 1.82 | 4.83 | 0.46 | 0.23 | 0.09 | 8.0 | | 9.7 | | 90 | | |
| 134.7 | 59.48 | 1.32 | 3.47 | 0.59 | 0.27 | 0.12 | 8.0 | | 9.7 | | 90 | | |
| 134.8 | 73.91 | 3.87 | 5.60 | 0.41 | 0.16 | 0.06 | 8.7 | | Riesgo | | 9.7 | | 90 |
| 134.9 | 76.11 | 2.90 | 3.88 | 0.39 | 0.11 | 0.09 | 8.0 | | Regular | | 9.7 | | 90 |
| 135.0 | 66.70 | 1.47 | 3.22 | 0.60 | 0.24 | 0.16 | 8.0 | | Regular | | 9.7 | | 90 |
| 135.1 | 34.77 | 0.24 | 2.89 | 0.96 | 0.40 | 0.26 | 4.0 | | Mala 1 | | 9.7 | | 90 |
| 135.2 | 68.83 | 4.70 | 7.39 | 0.34 | 0.21 | 0.08 | 9.0 | Riesgo | 9.7 | | 90 | | |
| 135.4 | 72.44 | 2.69 | 4.16 | 0.44 | 0.16 | 0.09 | 8.0 | Regular | 9.7 | | 90 | | |
| 135.5 | 79.65 | 4.61 | 5.23 | 0.30 | 0.09 | 0.05 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna | |
| 135.6 | 50.13 | 0.66 | 2.85 | 0.64 | 0.27 | 0.14 | 8.0 | Regular | 9.7 | | 90 | Monitoreo | |
| 135.7 | 37.65 | 0.61 | 3.57 | 0.65 | 0.34 | 0.12 | 8.0 | | 9.7 | | 90 | | |
| 135.8 | 69.30 | 2.23 | 4.96 | 0.58 | 0.22 | 0.11 | 8.0 | | 9.7 | | 90 | | |
| 135.9 | 63.35 | 1.87 | 4.15 | 0.40 | 0.16 | 0.07 | 8.2 | | 9.7 | | 90 | | |
| 136.0 | 77.52 | 3.16 | 5.68 | 0.46 | 0.17 | 0.07 | 8.2 | | 9.7 | | 90 | | |
| 136.1 | 71.18 | 1.75 | 4.54 | 0.63 | 0.28 | 0.13 | 8.0 | | 9.7 | | 90 | | |
| 136.2 | 73.32 | 2.97 | 4.92 | 0.49 | 0.23 | 0.10 | 8.0 | | 9.7 | | 90 | | |
| 136.3 | 74.01 | 3.96 | 5.41 | 0.42 | 0.19 | 0.09 | 8.9 | Riesgo | 9.7 | | 90 | | |
| 136.4 | 76.57 | 5.20 | 6.56 | 0.27 | 0.10 | 0.04 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna | |
| 136.5 | 76.95 | 3.95 | 5.14 | 0.37 | 0.13 | 0.07 | 8.9 | Riesgo | 9.7 | 90 | Monitoreo | | |
| 136.6 | 63.27 | 3.68 | 7.29 | 0.33 | 0.20 | 0.06 | 8.2 | Regular | 9.7 | 90 | | | |
| 136.7 | 75.37 | 5.77 | 7.36 | 0.38 | 0.20 | 0.07 | 9.0 | Riesgo | 9.7 | 90 | | | |
| 136.8 | 76.23 | 4.66 | 6.12 | 0.34 | 0.13 | 0.05 | 9.6 | Adecuada | 9.7 | 95 | Ninguna | | |
| 136.9 | 78.87 | 4.88 | 5.77 | 0.32 | 0.12 | 0.06 | 9.4 | | 9.7 | 92 | Monit-ning | | |
| 137.0 | 75.72 | 4.34 | 5.65 | 0.28 | 0.10 | 0.06 | 9.6 | | 9.7 | 95 | Ninguna | | |
| 137.1 | 73.43 | 3.84 | 5.40 | 0.26 | 0.10 | 0.06 | 9.3 | | 9.7 | 91 | Monitoreo | | |
| 137.2 | 77.91 | 2.99 | 5.68 | 0.41 | 0.12 | 0.09 | 8.0 | Regular | 9.7 | 90 | Monitoreo | | |
| 137.3 | 74.11 | 4.97 | 6.75 | 0.22 | 0.09 | 0.05 | 9.6 | Adecuada | 9.7 | 95 | | Ninguna | |
| 137.4 | 77.29 | 4.03 | 5.23 | 0.35 | 0.13 | 0.07 | 9.0 | Riesgo | 9.7 | 90 | Monitoreo | | |
| 137.5 | 79.21 | 4.64 | 5.64 | 0.33 | 0.11 | 0.06 | 9.5 | Adecuada | 9.7 | 93 | Monit-ning | | |
| 137.6 | 68.21 | 2.32 | 4.78 | 0.39 | 0.18 | 0.08 | 8.0 | Regular | 9.7 | 90 | Monitoreo | | |
| 137.7 | 80.50 | 3.71 | 4.84 | 0.50 | 0.22 | 0.09 | 8.7 | Riesgo | 9.7 | 90 | | | |
| 137.8 | 71.38 | 2.61 | 5.13 | 0.29 | 0.12 | 0.07 | 8.6 | 9.7 | 90 | | | | |
| 137.9 | 74.62 | 2.73 | 5.54 | 0.46 | 0.21 | 0.08 | 8.0 | Regular | 9.7 | 90 | | | |
| 138.0 | 74.47 | 3.31 | 6.62 | 0.34 | 0.13 | 0.07 | 8.5 | Riesgo | 9.7 | 90 | | | |
| 138.1 | 48.31 | 1.28 | 6.20 | 0.46 | 0.27 | 0.06 | 8.0 | Regular | 9.7 | 90 | | | |
| 138.2 | 74.12 | 2.66 | 5.78 | 0.39 | 0.16 | 0.08 | 8.0 | | 9.7 | 90 | | | |
| 138.3 | 29.28 | 0.36 | 3.70 | 0.67 | 0.41 | 0.16 | 7.8 | | 9.7 | 90 | | | |
| 138.4 | 53.58 | 0.84 | 4.01 | 0.49 | 0.26 | 0.10 | 8.0 | | 2.0 | Rotmed | 50 | MC y FR | |

| Absc. (km) | Modulos * 1000 (kg/cm2) | | | Indicadores (mm) | | | Rigidez | | Deterioro | | Eval. Integral | |
|---------------|-------------------------|------|------|------------------|------|------|----------|----------|------------|------------|----------------|-----------|
| | E1 | E2 | E3 | Dmax | BLI | MLI | Calific. | Condic. | Calific. | Condic | Calific. | Solución |
| 138.5 | 62.96 | 1.70 | 3.72 | 0.65 | 0.32 | 0.11 | 8.0 | Regular | 9.7 | Adecuada | 90 | Monitoreo |
| 138.6 | 67.01 | 1.57 | 4.29 | 0.64 | 0.33 | 0.11 | 8.0 | | 9.7 | | 90 | |
| 138.7 | 61.15 | 2.45 | 5.30 | 0.36 | 0.18 | 0.07 | 8.1 | | 9.7 | | 90 | |
| 138.8 | 77.75 | 5.09 | 6.38 | 0.26 | 0.07 | 0.04 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna |
| 138.9 | 71.81 | 5.10 | 7.06 | 0.31 | 0.15 | 0.05 | 9.6 | 9.7 | 95 | | | |
| 139.0 | 45.99 | 1.36 | 6.19 | 0.53 | 0.32 | 0.07 | 8.0 | Regular | 9.7 | | 90 | Monitoreo |
| 139.1 | 77.79 | 5.57 | 6.91 | 0.30 | 0.13 | 0.04 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna |
| 139.2 | 72.07 | 5.68 | 7.98 | 0.26 | 0.14 | 0.02 | 9.6 | | 9.7 | | 95 | |
| 139.3 | 44.47 | 0.50 | 3.45 | 0.61 | 0.34 | 0.13 | 8.0 | Regular | 9.7 | | 90 | Monitoreo |
| 139.4 | 77.38 | 4.98 | 6.76 | 0.30 | 0.10 | 0.04 | 9.6 | Adecuada | 9.7 | | 95 | Ninguna |
| 139.5 | 69.12 | 3.01 | 5.48 | 0.26 | 0.12 | 0.05 | 8.9 | Riesgo | 9.7 | 90 | Monitoreo | |
| 139.6 | 35.59 | 0.55 | 4.63 | 0.53 | 0.32 | 0.09 | 8.0 | Regular | 9.7 | 90 | | |
| 139.7 | 67.55 | 1.41 | 5.25 | 0.54 | 0.20 | 0.10 | 8.0 | | 9.7 | 90 | | |
| 139.8 | 55.48 | 0.56 | 2.79 | 0.69 | 0.34 | 0.17 | 8.0 | | 7.4 | Defmed-lig | 58 | MC |
| 139.9 | 75.64 | 1.93 | 3.68 | 0.70 | 0.27 | 0.16 | 8.0 | 7.0 | Defmedia | 55 | MC | |
| 140.0 | 59.91 | 1.93 | 5.69 | 0.34 | 0.19 | 0.07 | 8.1 | 7.4 | Defmed-lig | 58 | MC | |

ANEXO C: ALGORITMOS DESARROLLADOS - SISTEMAS DE INFERENCIA DIFUSOS

| RIGIDEZ | DETERIORO | SOLUCIONES |
|--------------------------------------|-----------------------------------|--------------------------------------|
| [System] | [System] | [System] |
| Name='Rigifin' | Name='Deterioro2' | Name='CalifiBis' |
| Type='mamdani' | Type='mamdani' | Type='mamdani' |
| Version=2.0 | Version=2.0 | Version=2.0 |
| NumInputs=6 | NumInputs=4 | NumInputs=2 |
| NumOutputs=1 | NumOutputs=1 | NumOutputs=1 |
| NumRules=37 | NumRules=33 | NumRules=65 |
| AndMethod='min' | AndMethod='min' | AndMethod='min' |
| OrMethod='max' | OrMethod='max' | OrMethod='max' |
| ImpMethod='min' | ImpMethod='min' | ImpMethod='min' |
| AggMethod='max' | AggMethod='max' | AggMethod='max' |
| DefuzzMethod='bisector' | DefuzzMethod='bisector' | DefuzzMethod='bisector' |
| | | |
| [Input1] | [Input1] | [Input1] |
| Name='E1' | Name='Roderas' | Name='Deterioro' |
| Range=[0 100] | Range=[0 12] | Range=[0 10] |
| NumMFs=3 | NumMFs=4 | NumMFs=8 |
| MF1='Bajo':trapmf,[-30 -20 20 25] | MF1='Adecuada':trapmf,[-5 -3 3 5] | MF1='RotSev':trapmf,[-2 -1 1 2] |
| MF2='Medio':trimf,[20 45 70] | MF2='ligera':trimf,[3 5 7] | MF2='RotMed':trimf,[1 2 3] |
| MF3='Alto':trapmf,[60 80 100 120] | MF3='media':trimf,[5 7 9] | MF3='GRlig':trimf,[2 3 4] |
| | MF4='severa':trapmf,[8 10 20 30] | MF4='BchLig':trimf,[3 4 5] |
| | | MF5='DefSev':trimf,[5 6 7] |
| [Input2] | [Input2] | MF6='DefMed':trimf,[5.97 6.97 7.97] |
| Name='E2' | Name='Grietas' | MF7='Deflig':trimf,[7 8 9] |
| Range=[0 10] | Range=[0 25] | MF8='Adecuada':trimf,[9 10 11] |
| NumMFs=4 | NumMFs=4 | |
| MF1='Bajo':trapmf,[0.01 0.01 3 4] | MF1='Adecuada':trimf,[-5 0 5] | [Input2] |
| MF2='Medio':trimf,[3.5 5 7] | MF2='ligera':trimf,[0 5 10] | Name='Rigidez' |
| MF3='Alto':trapmf,[6 7 10 13] | MF3='media':trimf,[5 12.5 20] | Range=[0 10] |
| MF4='NOBG':trimf,[-1 0 0.01] | MF4='severa':trapmf,[15 20 40 50] | NumMFs=9 |
| | | MF1='Pes1':trimf,[-1 0 1] |
| [Input3] | [Input3] | MF2='Pes2':trimf,[0 1 2] |
| Name='E3' | Name='BacheAb' | MF3='Pes3':trimf,[1 2 3] |
| Range=[0 10] | Range=[0 25] | MF4='Mala1':trimf,[3 4 5] |
| NumMFs=3 | NumMFs=4 | MF5='Mala2':trimf,[4 5 6] |
| MF1='Bajo':trapmf,[-4 -3 3 4] | MF1='Adecuada':trimf,[-0.1 0 0.1] | MF6='Mala3':trimf,[5 6 7] |
| MF2='Medio':trimf,[3.5 5 7] | MF2='ligero':trimf,[0.1 5 10] | MF7='Regular':trimf,[7 8 9] |
| MF3='Alto':trapmf,[6 7 10 13] | MF3='medio':trimf,[5 12.5 20] | MF8='Riesgo':trimf,[8 9 10] |
| | MF4='severo':trapmf,[15 20 40 50] | MF9='Adecuada':trimf,[9 10 11] |
| | | |
| [Input4] | [Input4] | [Output1] |
| Name='Dmax' | Name='BacheRep' | Name='Calificación' |
| Range=[0 1.6] | Range=[0 25] | Range=[0 100] |
| NumMFs=4 | NumMFs=4 | NumMFs=17 |
| MF1='Bueno':trimf,[-0.5 0 0.5] | MF1='Adecuado':trimf,[-5 0 5] | MF1='RECtot':trimf,[-5 0 5] |
| MF2='Riesgo':trimf,[0.4 0.6 0.8] | MF2='ligero':trimf,[0 5 10] | MF2='RecCAyBG':trimf,[0 5 10] |
| MF3='Severo':trimf,[1 1.6 2] | MF3='medio':trimf,[5 12.5 20] | MF3='RecCA':trimf,[5 10 15] |
| MF4='Grave':trimf,[0.7 0.9 1.1] | MF4='severo':trapmf,[15 20 40 50] | MF4='REyFR1':trimf,[15 20 25] |
| | | MF5='REF1':trimf,[20 25 30] |
| [Input5] | [Output1] | MF6='REyFR':trimf,[25.3 30.3 35.3] |
| Name='BLI' | Name='Deterioro' | MF7='REF':trimf,[30 35 40] |
| Range=[0 1] | Range=[0 10] | MF8='MC1':trimf,[40 45 50] |
| NumMFs=3 | NumMFs=8 | MF9='MCyFR':trimf,[45 50 55] |
| MF1='Buena':trimf,[-0.2 0 0.2] | MF1='RotSev':trapmf,[-2 -1 1 2] | MF10='MC':trimf,[50 55 60] |
| MF2='Riesgo':trimf,[0.1 0.3 0.5] | MF2='RotMed':trimf,[1 2 3] | MF11='Bach1':trimf,[60 65 70] |
| MF3='Grave':trapmf,[0.4 0.5 1 1.333] | MF3='Grietlig':trimf,[2 3 4] | MF12='Bach':trimf,[65 70 75] |
| | MF4='Bachlig':trimf,[3 4 5] | MF13='Reni':trimf,[70 75 80] |
| | MF5='Defsev':trimf,[5 6 7] | MF14='Sello1':trimf,[74.4 79.4 84.4] |
| | MF6='Defmed':trimf,[6 7 8] | MF15='Sello':trimf,[80 85 90] |
| | MF7='Deflig':trimf,[7 8 9] | MF16='Monit':trimf,[85 90 95] |
| | MF8='Adecuada':trimf,[9 10 11] | MF17='Nada':trimf,[90 100 110] |

| RIGIDEZ | DETERIORO | SOLUCIONES |
|--|----------------------|-----------------|
| [Input6] | [Rules] | [Rules] |
| Name='MLI' | 4 1 1 1, 5 (1) : 1 | 5 1, 1 (1) : 1 |
| Range=[0 0.4] | 0 4 4 4, 1 (1) : 2 | 1 1, 1 (1) : 1 |
| NumMFs=3 | 0 3 3 -4, 1 (1) : 1 | 5 4, 1 (1) : 1 |
| MF1='Bueno':'trimf',[-0.1 0 0.08] | 0 3 -4 3, 1 (1) : 1 | 1 4, 1 (1) : 1 |
| MF2='Riesgo':'trimf',[0.05 0.15 0.25] | 3 3 -4 -4, 1 (1) : 1 | 1 2, 2 (1) : 1 |
| MF3='Grave':'trapmf',[0.2 0.3 0.4 0.534] | -4 -4 3 3, 1 (1) : 1 | 5 2, 2 (1) : 1 |
| | 3 -4 3 -4, 1 (1) : 1 | 1 5, 2 (1) : 1 |
| [Output1] | 3 -4 -4 3, 1 (1) : 1 | 5 5, 2 (1) : 1 |
| Name='Rigidez' | 3 1 1 1, 6 (1) : 1 | 1 3, 3 (1) : 1 |
| Range=[0 10] | 0 3 3 3, 2 (1) : 2 | 5 3, 3 (1) : 1 |
| NumMFs=9 | 0 3 1 1, 2 (1) : 1 | 1 6, 3 (1) : 1 |
| MF1='Riesgo':'trimf',[8 9 10] | 0 1 3 1, 2 (1) : 1 | 5 6, 3 (1) : 1 |
| MF2='Mala1':'trimf',[3 4 5] | 0 1 1 3, 2 (1) : 1 | 5 7, 7 (1) : 1 |
| MF3='Pes2':'trimf',[0 1 2] | 0 3 2 1, 2 (1) : 1 | 1 7, 6 (1) : 1 |
| MF4='Mala2':'trimf',[4 5 6] | 0 3 1 2, 2 (1) : 1 | 5 8, 10 (1) : 1 |
| MF5='Pes1':'trimf',[-1 0 1] | 0 2 3 1, 2 (1) : 1 | 1 8, 9 (1) : 1 |
| MF6='Reg':'trimf',[7 8 9] | 0 2 1 3, 2 (1) : 1 | 6 1, 5 (1) : 1 |
| MF7='Pes3':'trimf',[1 2 3] | 0 1 2 3, 2 (1) : 1 | 6 2, 5 (1) : 1 |
| MF8='Mala3':'trimf',[5 6 7] | 0 1 3 2, 2 (1) : 1 | 6 3, 5 (1) : 1 |
| MF9='Adecuada':'trimf',[9 10 11] | 0 2 2 1, 2 (1) : 1 | 6 4, 7 (1) : 1 |
| | 0 2 1 2, 2 (1) : 1 | 6 5, 7 (1) : 1 |
| [Rules] | 0 1 2 2, 2 (1) : 1 | 6 6, 7 (1) : 1 |
| 1 0 1 3 0 0, 5 (1) : 1 | 2 2 1 1, 2 (1) : 1 | 6 7, 10 (1) : 1 |
| 1 0 1 4 0 0, 2 (1) : 1 | 2 1 2 1, 2 (1) : 1 | 6 8, 10 (1) : 1 |
| 1 0 1 2 0 0, 6 (1) : 1 | 2 1 1 2, 2 (1) : 1 | 2 1, 4 (1) : 1 |
| -1 1 1 3 0 3, 5 (1) : 1 | 0 2 2 2, 2 (1) : 1 | 2 2, 4 (1) : 1 |
| -1 1 1 -3 0 3, 2 (1) : 1 | 2 1 1 1, 7 (1) : 1 | 2 3, 4 (1) : 1 |
| -1 1 1 -3 -3 2, 6 (1) : 1 | 1 2 1 1, 3 (1) : 1 | 2 4, 6 (1) : 1 |
| 1 1 -1 3 3 0, 3 (1) : 1 | 1 1 2 1, 4 (1) : 1 | 2 5, 6 (1) : 1 |
| 1 1 -1 -3 3 0, 4 (1) : 1 | 1 1 1 2, 4 (1) : 1 | 2 6, 6 (1) : 1 |
| 1 1 -1 0 2 0, 6 (1) : 1 | 1 1 1 1, 8 (1) : 1 | 2 7, 9 (1) : 1 |
| -1 -1 1 3 0 3, 5 (1) : 1 | 4 2 1 1, 5 (1) : 1 | 2 8, 9 (1) : 1 |
| -1 -1 1 -3 0 3, 2 (1) : 1 | 3 2 1 1, 6 (1) : 1 | 7 1, 8 (1) : 1 |
| -1 -1 1 -1 0 2, 6 (1) : 1 | | 7 2, 8 (1) : 1 |
| -1 1 -1 3 3 0, 3 (1) : 1 | | 7 3, 8 (1) : 1 |
| -1 1 -1 -3 3 0, 4 (1) : 1 | | 7 4, 8 (1) : 1 |
| -1 1 -1 0 2 0, 6 (1) : 1 | | 7 5, 8 (1) : 1 |
| 1 -1 -1 3 3 0, 7 (1) : 1 | | 7 6, 8 (1) : 1 |
| 1 -1 -1 -3 3 0, 8 (1) : 1 | | 7 7, 13 (1) : 1 |
| 1 -1 -1 0 2 0, 6 (1) : 1 | | 7 8, 13 (1) : 1 |
| -1 -1 -1 3 0 0, 1 (1) : 1 | | 3 1, 14 (1) : 1 |
| -1 -1 -1 4 -3 0, 1 (1) : 1 | | 3 2, 14 (1) : 1 |
| -1 -1 -1 0 3 0, 1 (1) : 1 | | 3 3, 14 (1) : 1 |
| -1 -1 -1 0 0 3, 1 (1) : 1 | | 3 4, 14 (1) : 1 |
| -1 -1 -1 2 2 -3, 1 (1) : 1 | | 3 5, 14 (1) : 1 |
| -1 -1 -1 2 -3 2, 1 (1) : 1 | | 3 6, 14 (1) : 1 |
| -1 -1 -1 -3 2 2, 1 (1) : 1 | | 3 7, 15 (1) : 1 |
| -1 -1 -1 -4 2 2, 1 (1) : 1 | | 3 8, 15 (1) : 1 |
| -1 -1 -1 2 2 2, 1 (1) : 1 | | 4 1, 11 (1) : 1 |
| -1 -1 -1 1 1 1, 9 (1) : 1 | | 4 2, 11 (1) : 1 |
| 1 4 -1 -3 -3 -3, 6 (1) : 1 | | 4 3, 11 (1) : 1 |
| -1 4 1 3 0 3, 5 (1) : 1 | | 4 4, 11 (1) : 1 |
| -1 4 1 -3 0 3, 2 (1) : 1 | | 4 5, 11 (1) : 1 |
| -1 4 1 -3 -3 2, 6 (1) : 1 | | 4 6, 11 (1) : 1 |
| 1 4 -1 3 3 0, 7 (1) : 1 | | 4 7, 12 (1) : 1 |
| 1 4 -1 -3 3 0, 8 (1) : 1 | | 4 8, 12 (1) : 1 |
| 1 4 -1 0 2 0, 6 (1) : 1 | | 8 1, 16 (1) : 1 |
| -1 1 -1 1 1 1, 1 (1) : 1 | | 8 2, 16 (1) : 1 |
| -1 4 -1 1 -3 1, 9 (1) : 1 | | 8 3, 16 (1) : 1 |
| | | 8 4, 16 (1) : 1 |
| | | 8 5, 16 (1) : 1 |
| | | 8 6, 16 (1) : 1 |
| | | 8 7, 16 (1) : 1 |
| | | 8 8, 16 (1) : 1 |
| | | 8 9, 17 (1) : 1 |