



Universidad de Chile
Facultad de Ciencias Sociales
Departamento de Sociología

COMPLEJIDAD: TEORÍA Y MÉTODO

- Memoria para optar al título de Socióloga -

Autora:	Monica Gerber Plüss
Profesor Guía:	Manuel Vivanco Arancibia
Asesor Metodológico:	Rodrigo Asún Inostroza

AGRADECIMIENTOS

Fueron muchos y muy importantes los aportes y apoyos que recibí para sacar adelante este proyecto. Por lo mismo, quiero agradecer...

A mi profesor guía, Manuel Vivanco, por haberme presentado la complejidad y por haberme apoyado con su conocimiento a lo largo de este proyecto.

A Rodrigo Asún, por su apoyo en los aspectos metodológicos y, especialmente, por su entusiasmo y apoyo constante.

A Willy Gerber por haber tenido la paciencia de enseñarle física a una cientista social y por sus buenas ideas.

A Tito Elgueta por su apoyo constante, sus buenos consejos y su paciencia con mis miles de preguntas.

A Rodrigo Márquez, por sus grandes ideas.

A Elisabeth Wenk, por todas sus enseñanzas y apoyo constante.

Por último, le quiero agradecer a muchas personas que me han apoyado y acompañado a lo largo de esta memoria, entre ellas a mi familia, a Macarena Orchard, a Sofía Donoso y a Anamaría Silva.

ÍNDICE

I.	Introducción	4
II.	Planteamiento del Problema.....	6
III.	Objetivos.....	8
IV.	Marco Teórico.....	9
	1. La Noción de Paradigma y de Cambio Paradigmático	9
	2. La Teoría de la Complejidad.....	11
	2.1 El paradigma clásico	11
	2.2 Las anomalías de la Ciencia Clásica	16
	2.3 Los pilares de la complejidad.....	19
	a. La Cibernética	20
	b. Teoría de la información.....	22
	c. Teoría de Sistemas.....	22
	2.4 Las Generalidades de las Teorías de la Complejidad.....	29
	2.5 Las Especificidades de la Complejidad.....	50
	a. El Pensamiento Complejo	50
	b. Los Sistemas Disipativos	51
	c. Los Sistemas Complejos Adaptativos.....	54
	d. La Autopoiesis	56
	e. Teoría del Caos.....	60
	2.6. Conclusiones de las Teorías de la Complejidad	64
	3. Los Métodos de la Complejidad	67
	3.1 Los modelos causales recursivos.....	69
	3.2 Las Redes Neuronales Artificiales	78
V.	Marco Metodológico.....	92
	1. Tipo de investigación	92
	2. Diseño de la investigación	92
	3. Etapas del estudio	94
	4. Carta Gantt.....	94
	5. Relevancia	95
	6. Instrumento de Diagnóstico del Nivel de Complejidad de las Relaciones entre Variables	95
	7. Datos utilizados	100
	8. Diseño de las Técnicas de Análisis de Datos	124
	9. Hipótesis.....	126
VI.	Resultados.....	128
VII.	Discusión.....	136
VIII.	Conclusiones.....	138
IX.	Bibliografía	141

“Lo artificial es determinista y reversible. Lo natural contiene elementos esenciales de azar e irreversibilidad. Esto llama a una nueva visión de la materia en la que ésta ya no sea pasiva como la descrita en el mundo del concepto mecánico, sino asociada a la actividad espontánea. Este cambio es tan profundo que creo que podemos hablar con justicia de un nuevo diálogo del hombre con la naturaleza” (Prigogine, 2004, pp. 23-24).

I. Introducción

La ciencia clásica ha predominado no solamente en la manera de observar e investigar la realidad, sino también en la visión de mundo aceptada por todos nosotros. En términos kuhnianos, es posible entender esta ciencia como un paradigma, pues define el marco desde el cual se investiga, el objeto de estudio, así como también un modelo de pensamiento. Este paradigma fue establecido desde la física, principalmente desde los postulados de Newton y Laplace. La realidad, en este contexto, es asumida de manera mecanicista, determinista y analítica. Bajo esta lógica, todo fenómeno es posible de ser descrito si se analizan sus componentes. Tal vez lo más fundamental de esta visión, es que la predicción resulta posible, siempre y cuando, se conozcan todos los aspectos que influyen en cierto fenómeno. De esta manera, si se conoce la trayectoria de un objeto, es posible calcular su ubicación en un momento determinado. Las incapacidades de predicción se encuentran directamente relacionadas con la incapacidad del hombre para generar técnicas de medición cada vez más precisas. Bajo esta lógica, el mundo es posible de ser conocido en su totalidad, es solo una cuestión de tiempo¹.

¹ Una consecuencia del éxito de este paradigma en las ciencias naturales, fue su constante intento de aplicación a las ciencias sociales. Hasta hoy en día, es posible afirmar que el logro de este ajuste ha sido solamente relativo.

Sin embargo, desde una visión kuhniana, cierto paradigma predomina hasta el momento en que se empiezan a observar eventos que no es posible explicar por medio de la ciencia predominante. A estos eventos Kuhn le denomina anomalías. Es en este momento, que empiezan a buscarse paradigmas alternativos que puedan explicar aquellos ámbitos que el paradigma anterior no fue capaz de resolver. La historia de la ciencia no se encuentra libre de estos eventos.

Tal vez los sucesos más relevantes que cuestionaron al paradigma clásico fueron la mecánica cuántica y la teoría de la relatividad. Lo sorprendente de estos sucesos, es que la crítica a la ciencia clásica nació desde la misma física, ciencia conocida por ser el ámbito en el que este paradigma mejor funcionaba. Sin embargo, empezó a ser evidente que el paradigma clásico era aplicable solamente en un ámbito de los fenómenos. Por ejemplo, que presentaba problemas al intentar predecir en ámbitos micros y macros.

Las implicancias de la observación de estas anomalías fueron enormes. Por un lado, se empezó a desarrollar conocimiento nuevo para explicar los fenómenos que estaban quedando fuera del paradigma clásico y, por otro, fueron apareciendo una serie de temáticas en el debate, temáticas que antes habían sido excluidas del ámbito de la ciencia. Entre estas es posible nombrar a la incertidumbre, al desorden, las fluctuaciones, entre otras. En todo caso, es importante destacar que, sin embargo, la ciencia clásica no ha perdido su predominio en los ámbitos clásicos de su aplicación.

Para las ciencias sociales esto tiene, a su vez, importantes consecuencias. Es una hipótesis subyacente de esta investigación, que si bien las ciencias sociales habían intentado aplicar el paradigma clásico de la física en el estudio de los fenómenos sociales, esto no alcanzó el éxito esperado, justamente por el hecho de que en este ámbito los fenómenos que no funcionan bajo las leyes del paradigma clásico son muchos más. En el ámbito social, es mucho más fácil encontrar relaciones con múltiples causas, con un importante efecto de interacciones, con comportamientos no lineales, entre otros. De hecho, es difícil encontrar relaciones que puedan ser explicadas de manera determinista, con una sola causa, y, por lo tanto, que sean fácilmente predecibles.

Es en este contexto que surgen las visiones sobre la complejidad. Si bien es difícil hablar de una sola teoría, dada la diversidad de escuelas, estas teorías presentan semejanza tanto en la crítica que realizan a la ciencia clásica, como en cuánto a distintas temáticas que son consideradas como fundamentales para elaborar una nueva ciencia. Sin embargo, el surgimiento de una teoría no puede ser analizado sin tomar en cuenta el método de investigación que esta propone. Es posible afirmar, en este sentido, que si bien las teorías de la complejidad presentan una gran semejanza en términos teóricos y conceptuales, no ocurre lo mismo con los métodos. No existe aún un acuerdo sobre cuál es el método de la complejidad y esto, a su vez, es un requisito ineludible para la constitución de un paradigma.

II. Planteamiento del Problema

La siguiente investigación tiene por objeto trabajar en las dos temáticas anteriormente nombradas. Por un lado, el desarrollo de las teorías de la complejidad y de su aplicación y, por otro, el del método y las técnicas asociadas a las mismas.

Con respecto al desarrollo de las teorías, interesa indagar en los temas comunes que presentan los distintos autores y escuelas que trabajan el tema de la complejidad. De esta manera, es posible elaborar una caracterización de los principales elementos de la complejidad y de las distintas visiones que los autores tienen con respecto a estos. A su vez, es posible indagar en los planteamientos propios de cada autor/escuela, de manera de armar un catastro de los avances de la complejidad en distintos ámbitos. En este contexto, tal vez lo más interesante, es preguntarse acerca de cómo se conjugan los factores comunes con los específicos, así como los acuerdos con los desacuerdos, de manera de evaluar si es posible hablar de un paradigma que se encuentra en proceso de construcción.

Resumiendo, esta investigación pretende contestar las siguientes preguntas: *¿Cuáles son los elementos característicos de la complejidad, comunes a los distintos autores? ¿Cómo son abordados por los distintos autores/escuelas de la complejidad? ¿Cuáles son los elementos específicos que distintos autores tratan? Por último, ¿es posible hablar de la existencia de un paradigma de la complejidad?*

Por otro lado, como resultado de la aparición de las teorías de la complejidad, surge la pregunta de cómo investigar en este contexto, específicamente, de qué técnicas deben ser usadas para describir una realidad con características complejas. En esta investigación se plantea que los Modelos Causales Recursivos y, en mayor medida, las Redes Neuronales Artificiales presentan características que las convierten en técnicas aptas para trabajar en el contexto de la complejidad. De esta manera, interesa discutir las características que presentan y como estas logran representar los postulados de la complejidad. Especialmente interesante resulta comparar estas características con las técnicas estadísticas clásicas de análisis de datos. De hecho, es una hipótesis de este trabajo que distintas técnicas responden a paradigmas distintos y, que por lo tanto, su aplicación y rendimiento en distintos contextos es también distinta.

En este ámbito, cabe preguntarse, *¿presentan las Redes Neuronales Artificiales y los Modelos Causales Recursivos características de la complejidad en su funcionamiento?*, y a su vez, *¿es posible afirmar que a medida que aumenta la complejidad de las relaciones que se intenta estudiar, las técnicas estadísticas con características complejas presentan un rendimiento cada vez mayor?* Por último, evaluando el rendimiento de las distintas técnicas y considerando también el grado de dificultad de su aplicación, *¿qué técnicas son recomendables para ser utilizadas en distintos ámbitos?*

III. Objetivos

Objetivos Generales

- Describir los aspectos comunes de las distintas teorías de la complejidad, de manera de poder indagar en la posible construcción de un paradigma unitario de la complejidad.
- Evaluar las técnicas con características complejas en cuanto a su capacidad predictiva en ámbitos de distinto nivel de complejidad y contrastándolas con las técnicas clásicas de análisis.

Objetivos Específicos

- Evaluar la posibilidad de la construcción de un paradigma unitario de la complejidad.
- Determinar las principales características comunes de la complejidad, en base a los distintos temas tratados por los autores.
- [A partir de la definición de los aspectos comunes], elaborar un instrumento de diagnóstico del nivel de complejidad de relaciones entre variables.
- Evaluar la adaptación de las Redes Neuronales Artificiales y los Modelos Causales Recursivos a las teorías de la complejidad.
- Comparar la capacidad predictiva de técnicas clásicas de análisis y técnicas con características complejas, en relaciones entre variables con distintos niveles de complejidad.
- Comparar la capacidad predictiva de las técnicas en distintos ámbitos con la dificultad de su aplicación, de manera de poder recomendar su uso tomando en cuenta ambos aspectos.

IV. Marco Teórico

1. La Noción de Paradigma y de Cambio Paradigmático

Antes de empezar a revisar los postulados de la teoría de la complejidad, resulta necesario revisar los conceptos kuhnianos de paradigma y cambio paradigmáticos, de manera de poder encauzar el análisis del paso de la ciencia clásica a las teorías de la complejidad. A su vez, resulta fundamental para discutir si efectivamente es posible hablar de un paradigma de la complejidad.

La tesis de Thomas Kuhn sobre la ciencia aparece claramente definida en su libro *La Estructura de las Revoluciones Científicas* (1962), en el cuál el autor presenta una visión externalista de la ciencia, criticando de esta manera las visiones internalistas, predominantes hasta la fecha. Para Kuhn, no es posible entender el devenir de la ciencia, sin tomar en cuenta factores externos a la misma, como lo son la historia de las ideas y el desarrollo histórico en general.

Según Kuhn, las disciplinas científicas se desarrollan de acuerdo a un patrón general, atravesando una serie de etapas. En la primera etapa, denominada pre paradigmática, no se podría hablar aún de ciencia (Pérez, 1999). En este punto, distintas concepciones de la naturaleza, tanto en términos conceptuales como metodológicos, se encuentran en competencia por el predominio dentro del campo científico (Lamo De Espinoza, González y Torres, 1994). En esta etapa no es posible producir un cuerpo acumulativo de conocimiento (Pérez, 1999).

En un momento determinado, la comunidad de científicos asume esta concepción como forma de ver, entender y explicar los problemas de una disciplina, convirtiendo esta concepción en un paradigma (Lamo De Espinoza et al, 1994). Según Pérez (1999), un paradigma es adoptado si provee de una teoría y una técnica que permitan hacer predicciones acerca de una gama de fenómenos naturales. La teoría debe parecer mejor que las competidoras, aunque no sea capaz de explicar todos los sucesos (Kuhn, 2000).

Si bien Kuhn utiliza el término paradigma en muchos sentidos distintos, Masterman (en Lamo de Espinoza et al, 1994) afirma –siendo ratificada posteriormente por el mismo autor- que es posible reducir estos sentidos a tres:

- Un aspecto cognitivo, el cual incluye tanto proposiciones teóricas y metodológicas, como el trasfondo ontológico que las anteriores llevan implícitas.
- Una vertiente social del quehacer científico, lo que permite equiparar una comunidad científica a un paradigma. De esta manera, el paradigma aúna un lenguaje y una educación común.
- Un conjunto de realizaciones científicas que definen los problemas y sus soluciones a una comunidad científica.

Otro tema relevante acerca de los paradigmas, es que proporcionan las herramientas para formular y seleccionar los problemas legítimos (Pérez, 1999). De esta manera, también definen sobre qué es posible problematizar.

Luego de la instauración de un paradigma, se vive una etapa de ciencia normal. Kuhn (2000, p.33) define esta etapa como la *"investigación basada firmemente en una o más realizaciones científicas pasadas, realizaciones que alguna comunidad científica particular reconoce, durante cierto tiempo, como fundamento para su práctica posterior"*. En esta etapa, el enfoque teórico del paradigma aceptado se va articulando cada vez mejor. El potencial explicativo y predictivo del enfoque se va desarrollando al máximo (Pérez, 1999). En la etapa de ciencia normal, los supuestos básicos no se problematizan ni revisan, sino que son asumidos por la comunidad científica como base desde la cual trabajar.

En un momento determinado, empiezan a aparecer problemas que no pueden ser resueltos con el paradigma en cuestión. A estos problemas Kuhn les llamó anomalías. Se genera una etapa de crisis. En estos momentos empiezan a aparecer teorías que dan respuesta a esta crisis y que permiten construir un paradigma alternativo (ciencia extraordinaria), el cuál tiene más éxito que el anterior, en solucionar la anomalía.

En este momento, ocurre lo que Kuhn denomina como una Revolución Científica, la cuál implica un episodio de discontinuidad entre dos paradigmas alternativos e inconmensurables. Por lo tanto, cuando ocurre una revolución, se produce un cambio, tanto en los problemas admisibles y en las soluciones legítimas, reconstruyéndose completamente el campo científico, desde sus fundamentos, sus generalizaciones teóricas elementales y en los métodos y aplicaciones del mismo. Luego de una revolución, la comunidad rechaza el paradigma existente anteriormente (Lamo de Espinosa et al, 1994). Este paso de un paradigma a otro, es, según Kuhn (2000), el patrón usual de desarrollo de una ciencia madura.

Luego de un tiempo de debate y deliberación, se llega a un nuevo consenso en torno a uno de los paradigmas, volviendo a comenzar una etapa de ciencia normal (Lamo De Espinoza et al, 1994).

2. La Teoría de la Complejidad

2.1 El paradigma clásico

Las teorías de la complejidad no pueden ser entendidas sin hacer referencia a lo que había antes de ellas. Esto, dado que la complejidad surge, en gran medida, como una crítica a la manera clásica de hacer ciencia. Por esta razón, se revisarán a continuación los principales postulados de la ciencia clásica para luego analizar las anomalías que fueron surgiendo en la misma y los aspectos que ya no era capaz de explicar.

Al modelo imperante de la ciencia de los últimos siglos se le ha dado varios nombres. En general, estos nombres surgen justamente en aquellos contextos en que este modelo es criticado o en aquellos en los que se plantea el surgimiento de un nuevo paradigma. De esta manera, se habla del modelo reduccionista, mecánico (Buckley, 1967), de la ciencia clásica o newtoniana (Wiener, 1969). Para efectos de este estudio, se hablará de ciencia clásica, dado que es el término más neutro y amplio posible.

Resulta difícil delimitar, tanto en fechas como en contenido, un paradigma de la ciencia clásica, distinto a las teorías de la complejidad. Sin embargo, Wiener (1969) llega hasta a ponerle fechas. Según el autor, la física newtoniana habría reinado entre los siglos XVII y XIX sin ninguna oposición. Capra (2003a) afirma que este proceso, si bien no de manera lineal, predominó por lo menos hasta el siglo XIX. Si bien los límites pueden resultar complicados de fijar, existe bastante acuerdo entre distintos autores sobre los supuestos y contenidos de esta ciencia. A su vez, como se verá más adelante, existe bastante acuerdo entre los autores de la complejidad, en las críticas que deben hacerse.

Dado que esta ciencia se basa en una serie de supuestos y métodos aceptados por la comunidad de científicos, en base a los cuales ha podido acumular conocimiento, es posible afirmar que constituye un paradigma que en los últimos siglos ha atravesado una época de ciencia normal.

A continuación se procederá a describir los postulados de la ciencia clásica, los cuales sustentaron toda la investigación realizada en los últimos siglos:

❖ **Determinismo y Mecanicismo**

Según el ideal laplaciano, si se conoce la posición y momento de las partículas, es posible predecir el estado del universo en un momento cualquiera, pasado o futuro. Este mismo supuesto fue compartido por la mayoría de los científicos desde Descartes hasta Newton, llevándolos a imaginar el universo como una máquina determinista perfecta (Capra, 2003a; Morin, 2005; Prigogine y Stengers, 1990; von Bertalanffy, 1968;). Newton fue quién estableció la mecánica newtoniana en el siglo XVII (Capra, 2003a). El universo que esta ciencia describía, era una totalidad perfectamente organizada, que era capaz de explicar todo de manera exacta, dado que el futuro se encontraba en relación de dependencia con respecto al pasado. El universo newtoniano funcionaba con un mecanismo de relojería, de manera completamente determinista (Martínez, 1997). El correlato de esto era que el mundo no era un misterio, sino que podía ser explicado de manera simple y clara (Balandier, 1988) y que podía alcanzarse un conocimiento completo del mismo con total certidumbre (Prigogine, 1997). Según Morin (1984; 2005) para llegar a esta

conclusión fue necesario el rechazo de todo lo que fuera accidental, aleatorio e individual, así como las fluctuaciones y la inestabilidad, dejando reinar los principios del orden y de la estabilidad. De esta manera, las contradicciones eran asumidas como errores. Para Morin, el conocimiento científico clásico era el estudio del Orden perfecto, creado por una máquina perfecta (el cosmos).

❖ **Reduccionismo**

Este concepto es tan relevante para la descripción de la ciencia clásica, que de hecho muchos autores le han llamado a este paradigma, el enfoque reduccionista (Johansen, 1994; Briggs y Peat, 1989). El reduccionismo o enfoque analítico hace alusión a un principio cartesiano, según el cual los problemas son analizados de manera fragmentada. Desde este supuesto es posible, por medio de la adición, comprender el todo como la suma de las partes. Por lo tanto, el reduccionismo deja de lado toda conceptualización de sistema y de organización, así como el papel del entorno, intentando explicar los hechos por medio de la explicación de sus componentes (Briggs y Peat, 1989; Capra, 2003a; Johansen, 1994; Martínez, 1997; Morin, 1984; 2001; Rodríguez y Arnold, 1999; von Bertalanffy, 1968). Para Morin (1984; 2005), el conocimiento científico estudiaba una máquina que estaba compuesta por micro elementos, los átomos, que se reunían en objetos y sistemas. Según el autor, debido a esta idealización, lo complejo fue tratado como simple. Por estas razones, varios autores denominan a este paradigma, el paradigma de la simplificación (Morin, 1984; 2005; Roger, 2001).

❖ **El tiempo reversible**

El determinismo newtoniano y laplaciano partía de un supuesto fundamental: la reversibilidad del tiempo (Morin, 1984; Prigogine, 2004). En la ciencia clásica se estudian las trayectorias espacio-temporales, las cuales pueden ser descritas de manera completa por medio de un conjunto de puntos (Prigogine y Stengers, 1990). Todo el sistema de ecuaciones newtonianas funciona de manera reversible. Esto quiere decir que la ley es la misma si se predice el futuro o el pasado. Si se conjuga esto con el principio laplaciano, se asume que por medio del conocimiento del estado

de un sistema en un momento determinado, es posible deducir toda evolución futura, así como todo el pasado (Prigogine, 1997). Por lo tanto, bajo este supuesto, la ciencia no tiene historia (Byrne, 1998; Prigogine, 2004).

❖ **Delimitación de las ciencias**

Bajo el mismo enfoque analítico, se partió del supuesto que las ciencias debían, a su vez, encontrarse delimitadas. Esto se justificaba, en cuanto las unidades de análisis de las distintas ramas del saber eran distintas (Johansen, 1994; Rodríguez y Arnold, 1999). Para Morin (1984), la ciencia clásica es compartimentada y fragmentada, lo que ha llevado a la disyunción de las ciencias de la naturaleza de las ciencias del hombre.

❖ **Linealidad**

Por mucho tiempo no se contó con las técnicas matemáticas, ni con la comodidad de los computadores, para calcular ecuaciones no lineales. Debido a esto, en esta época se realizaban aproximaciones lineales, y todos los análisis se realizaban en este contexto (Briggs y Peat, 1989; Waldrop, 1992). Capra (2003a) afirma que esto hizo que los científicos pensaran que todos los fenómenos podían ser descritos por medio de ecuaciones lineales. A su vez, según Briggs y Peat (1989), fue por medio de este método que se logró preservar el viejo hechizo reduccionista. Unido a esto, Morin (1984) plantea que la causalidad era asumida como lineal, superior y exterior a los objetos.

❖ **Eliminación del Observador**

Descartes, por medio de la definición del dualismo entre mente y materia, llevó a la ciencia a asumir que el mundo podía ser descrito de manera objetiva, sin tomar en cuenta al sujeto (Martínez, 1997). Según Morin (1984), el asumir que sujeto y objeto se encuentran totalmente separados hizo que no se problematizara el papel del sujeto en el conocimiento. De esta manera, el mundo según Laplace y Newton era un

mundo totalmente independiente, tanto de la actividad experimental, como de los distintos puntos de vista (Prigogine y Stengers, 1990). Esto implicaba, por un lado, que el observador no afecta lo observado, y, por el otro, que todo observador describirá de igual manera lo que observa. En términos concretos, todo lo anterior asumía una realidad objetiva (Prigogine y Stengers, 1990), que podía ser estudiada por medio de la racionalidad del conocimiento y de la verdad (Martínez, 1997).

❖ **Idea del progreso ilimitado**

El concepto de un mundo que podía ser descrito de manera exacta por medio del conocimiento de sus componentes, el éxito de la física, de la mecánica y de la matemática llevó a la generación de una confianza inigualable en el progreso de la ciencia (Rodríguez y Arnold, 1999). La ciencia clásica asumió por mucho tiempo que se encontraban en un proceso científico acumulativo. En este sentido, solo era cosa de tiempo hasta que todas las leyes fueran conocidas (Prigogine, 1997b). De hecho, Laplace (en Prigogine y Stengers, 1990) llegó al punto de afirmar que no podían existir dos Newtons, porque no habría un segundo mundo a descubrir. Debido a este éxito, también la interpretación del hombre y de la sociedad empezó a ser abordada desde la misma lógica (Buckley, 1967; Pérez-Taylor, 2002). De hecho, Buckley (1967) hace referencia a la física social del siglo XVII, como la ciencia que buscaba estudiar la mecánica social, concibiendo a la sociedad como un sistema astronómico y a las personas como elementos que se unen por la atracción mutua o se separan por repulsión.

A modo de resumen, Prigogine y Stengers (1990) afirman que para Newton la teoría científica debía ser universal, determinista, objetiva, es decir, sin referencia al observador.

De esta manera, se observa como en la ciencia clásica existió un constructo sólido de supuestos compartidos en base a los cuáles se realizó investigación por varios siglos. A continuación se analizarán las anomalías que surgieron a lo largo del Siglo XX y que situaron en escena ámbitos donde la ciencia clásica no era posible de otorgar una explicación.

2.2 Las anomalías de la Ciencia Clásica

Según Kuhn, la ciencia normal sigue su proceso hasta el momento en que resulta incapaz de explicar algún fenómeno. Esto no quiere decir que la ciencia anterior quede obsoleta, sólo que existen ámbitos donde no puede ser utilizada. La ciencia clásica se ha encontrado con más de una anomalía en este último siglo. Prigogine y Stengers (1990) afirman que la ciencia clásica ha alcanzado sus propios límites, especialmente en cuanto a descubrir que sus conceptos clásicos tienen límites de validez universal. Según Capra (2003a), hay que tomar en cuenta que los cambios que se vivieron en la física predijeron cambios similares en otras ciencias.

Es discutible cuáles fueron las primeras anomalías que cuestionaron a la ciencia clásica. Morin (1984) y Prigogine y Stengers (1990) concuerdan en que la primera ciencia no clásica fue la termodinámica. A su vez, Morin (1984) y Nicolis y Prigogine (1997) afirman que las dos grandes revoluciones de la física de comienzos del siglo XX fueron la mecánica cuántica y la teoría de la relatividad.

Sin embargo, es imposible olvidar otra anomalía que, si bien no implicó un cambio paradigmático de la ciencia, cambió su enfoque de manera drástica. Este es el caso de la introducción de las probabilidades a la ciencia. A su vez, tampoco puede olvidarse la introducción de la flecha del tiempo y de las inestabilidades.

A continuación se describirán estas anomalías, de manera de poder entender los aspectos desde los cuales las teorías de la complejidad se aferraron para criticar a la ciencia clásica:

❖ La introducción de la probabilidad

Según Wiener (1969), la introducción de la probabilidad por Gibbs fue la primera revolución importante en la física del siglo XX. Esta revolución fue determinante, ya que cambió el enfoque de la predicción exacta, por una predicción en términos de probabilidades. Según el autor, la probabilidad es hoy asumida no solo como una herramienta matemática, sino como una parte esencial de la física. Sin embargo,

según Bertalanffy (1968), la visión mecanicista no fue alterada cuando se reemplazaron las leyes deterministas por leyes probabilísticas.

❖ **La introducción de la flecha del tiempo**

La termodinámica, específicamente por medio de su segundo principio, introdujo la flecha del tiempo en la física (Prigogine y Stengers, 1990). Esto implicó la introducción de la historia del universo, convirtiendo a los procesos reversibles y deterministas en idealizaciones (Prigogine, 2004). Este proceso se analizará con mayor detención más adelante.

❖ **La introducción de las inestabilidades**

Según Prigogine (1997), en el momento en que se empezó a introducir inestabilidades en la ciencia, las leyes de la naturaleza cambiaron. Un correlato de esto fue la necesidad de expresarlas en términos de probabilidades. Prigogine (2004) afirma que la física de los estados de no equilibrio permite analizar las propiedades de la materia cuando se encuentra lejos de estados de equilibrio. La moderna teoría de los sistemas dinámicos le da importancia a las inestabilidades y al hecho de que pequeñas variaciones de las condiciones iniciales pueden dar lugar a grandes efectos. A su vez, Morin (2005) afirma que lo propio de lo vivo no son las leyes del equilibrio, sino del desequilibrio, es decir, de un dinamismo estabilizado.

❖ **La mecánica cuántica**

Antes de la aparición de la mecánica cuántica, se asumía que las leyes físicas eran aplicables a todos los ámbitos, incluidos los micro y macrosistemas. La mecánica cuántica demostró que, si bien es posible aplicar las leyes de la dinámica clásica y la termodinámica a niveles macro, en el nivel micro es necesario utilizar otras leyes (Prigogine, 1997b). Capra (2003b) afirma que con los trabajos de Planck y Einstein apareció la primera paradoja cuántica, según la cual la luz se comporta a veces como ondas y a veces como partículas. Prigogine y Stengers (1990) explican

que en la mecánica cuántica se reemplazó el concepto de trayectoria por el de función de onda. Lo que demostró la mecánica cuántica es que los objetos materiales sólidos de la física se comportan a nivel subatómico en base a pautas de probabilidades, en forma de ondas. A su vez, es solamente posible medir probabilidades de relaciones y no de cosas. Por lo tanto, las partículas subatómicas pierden significado como entidades aisladas.

Tal vez el desarrollo más conocido de la teoría cuántica son los trabajos de Heisenberg. Según su principio de incertidumbre, a nivel subatómico la materia no se encuentra con seguridad en un lugar determinado a un tiempo preciso, sino que muestra tendencias (Capra, 2003b). Esto se traduce en que existe una imposibilidad de conocer con una alta precisión tanto la posición como la velocidad de una partícula subatómica al mismo tiempo (Briggs y Peat, 1989; Zúñiga, 2003). Este principio, por lo tanto, lleva a la necesidad de introducir la probabilidad en la descripción de la conducta de las partículas (Capra, 2003b; Briggs y Peat, 1989).

A su vez, Heisenberg (en Briggs y Peat, 1989; Martínez, 1997; Zúñiga, 2003) afirma que ningún objeto atómico tiene propiedades independientes de su entorno. Sus propiedades dependen de la situación experimental, esto es, el experimento influye en el sistema que está observando. El problema es que, en un sistema atómico, la perturbación que ocurre debido a la medición es tan grande como el sistema mismo. Por lo tanto, la medición perturba tanto el sistema, que se borra toda información posible sobre su estado anterior a la medición. Como conclusión, no es posible conocer la cosa en sí, si no es con un grado de probabilidad. Por lo tanto, es necesario introducir un carácter estadístico en las realidades subatómicas. A su vez, significa que ya no es posible seguir asumiendo que el observador es externo a lo observado.

Una conclusión importante de la mecánica cuántica es que la imprecisión no tiene que ver con los instrumentos de medición, sino que es una imprecisión intrínseca (Martínez, 1997). Por lo tanto, en la microfísica el objeto de estudio se vuelve incierto (Briggs y Peat, 1989) y se cuestiona si la noción de partícula elemental sigue teniendo sentido (Morin, 1984).

❖ **La teoría de la relatividad**

Para la física newtoniana, el tiempo era universal y común a todos los observadores. Sin embargo, la relatividad cambió este concepto (Prigogine, 1997). Según la relatividad, es necesario diferenciar entre bajas y altas velocidades. Los objetos físicos se comportan de manera distinta si la velocidad se acerca a la de la luz o si es mucho menor. De esta manera, la relatividad modificó el concepto clásico de objetividad física. Por lo tanto, la descripción no puede ya ser asumida como una medición del mundo desde afuera (Prigogine y Stengers, 1990), sino que es necesario tomar en cuenta el lugar del observador en la medición (Martínez, 1997; Morin, 2005). Desde ahora en adelante, es necesario tomar en cuenta tiempo y espacio de manera conjunta, asumiendo que se encuentran íntimamente relacionados, conformando una continuidad espacio tiempo (Lasky, 2002; Morin, 1984; Prigogine, 1997).

La mecánica cuántica y la teoría de la relatividad demostraron algo fundamental para la ciencia: el determinismo no es la regla, sino un caso puntual. Como afirma Morin (2005), lo simple no es más que un momento entre dos complejidades: la complejidad micro-física y la complejidad macro-física.

2.3 Los pilares de la complejidad

Luego del surgimiento de las anomalías descritas, fueron apareciendo críticas que se fueron forjando en teorías. De esta manera, Kuhn afirma que cuando aparecen anomalías, vuelven a ponerse en disputa distintas escuelas que pretenden encontrar una mejor forma de hacer ciencia. Las teorías de la complejidad surgen en este contexto. En este capítulo se analizarán los principales supuestos de las distintas teorías de la complejidad, de manera de evaluar si estas pueden ser asumidas como un solo paradigma.

Sin embargo, antes de llegar a los postulados de la complejidad, es necesario abordar una serie de teorías que fueron necesarias para sentar las bases de un pensamiento complejo.

Según Morin (2005) la "scienza nuova" se debe esbozar atravesando la cibernética, el sistemismo y la teoría de la información. De hecho, afirma que la teoría de sistemas es la raíz de la complejidad (Morin, 2001). Lo más importante de la cibernética y de la teoría de sistemas, es aportar los elementos para concebir la organización (Morin, 1984).

Por lo tanto, a continuación se procederá a presentar estos marcos conceptuales con el fin de resumir de manera esquemática –y por lo mismo, no exhaustiva- los pilares de la complejidad.

a. La Cibernética

Según Morin (2005), es con la cibernética que la complejidad entra verdaderamente en escena en la ciencia. La Cibernética fue desarrollada por Norbert Wiener en el MIT. La palabra cibernética proviene del griego *kybernetes*, que significa un tipo de control, específicamente, el timoneo de una goleta (Rodríguez y Arnold, 1999). Según Wiener (1969) esta palabra es la misma raíz de la cual pueblos de occidente han formado la palabra gobierno. La cibernética es la ciencia que explica los mecanismos de comunicación y control en las máquinas y en los seres vivos, basándose en los principios de retroalimentación y de homeostasis. Estos sistemas se caracterizan por estar motivados por la búsqueda de un objetivo, y por tener capacidades de auto-organización y de auto-control (Johansen, 1994; Rodríguez y Arnold, 1999).

Según Krippendorg (en Rodríguez y Arnold, 1999), la idea más fértil de la cibernética es la de la circularidad. Este concepto quiere decir que si A causa B y B causa C, mientras C, a su vez, causa A, A termina siendo autocausado. De esta manera, un sistema con esas características tiene la capacidad de autorregularse. Así, las formas de organización y las metas se definen en una relación mutua. Wiener (en Rodríguez y Arnold, 1999, p.44) define la retroalimentación como "*la propiedad de ajustar la conducta futura a hechos pasados*". Por lo tanto, una máquina es capaz de regular su comportamiento de acuerdo a su funcionamiento real y no con respecto a lo que se espera de ella. Los autores de la cibernética reconocían a la retroalimentación como el concepto fundamental que permitía la

autorregulación para que organismos vivos se pudieran mantener en un estado de equilibrio dinámico (Capra, 2003a).

Para Wiener (1969), la comunicación juega un papel fundamental para la autorregulación, dado que es por medio de esta que se regulan los actos de otras personas. De hecho, según el autor, los mensajes son una forma de organización. La comunicación está sometida a deformaciones al pasar de un ente a otro. Así, tanto en las comunicaciones como en la regulación, se lucha contra la tendencia de la naturaleza a degradar lo organizado, es decir, a aumentar su entropía. De hecho, la información es utilizada para ajustarse a las contingencias del medio y para vivir de manera efectiva dentro de él. Los organismos que son capaces de comunicarse, pueden considerar el ambiente como experiencia pasada y así modificar la conducta, actuando de manera más efectiva sobre el medio futuro. En este sentido, estructuras flexibles son capaces de aumentar la capacidad de algunos seres (Wiener, 1969).

Wiener también analiza la comunicación en relación a la entropía. Afirma que, *"Así como el monto de información en un sistema es una medida de su grado de organización, la entropía de un sistema es una medida de su grado de desorganización; y la una es simplemente el negativo de la otra"* (en Rodríguez y Arnold, 1999, p.44). El hombre, en su relación con el entorno, considera los procesos de regulación y de comunicación. Por medio de estos, logra reducir la tendencia entrópica (tema que se verá en mayor profundidad más adelante).

Para Morin (2001) una de las originalidades de la cibernética fue concebir la comunicación en términos organizacionales. De hecho, según el autor, la cibernética es la primera ciencia que, después del progreso de la ciencia occidental del siglo XVII, fundó su método no en función de sus elementos constitutivos, sino en términos de su organización. También Capra (2003a) rescata que los conceptos de mensaje, control y retroalimentación de Wiener se referían a las pautas de organización.

b. Teoría de la información

La teoría de la información nació con fines prácticos, en la búsqueda por transmitir mensajes de forma más económica y fiable. Se empezó por analizar emisores y receptores. El principal problema tratado fue que el de la degradación de la información. Dado que la información pasa a través de un canal en el cual surgen perturbaciones o ruido, la información se termina degradando (Morin, 1984; 2001).

Shannon, quien es considerado el padre de la teoría de la información, definió la información como una magnitud observable y medible (Johansen, 1994; Morin, 2001). Sin embargo, la definió en términos estadísticos, por lo tanto, la medida de información es un promedio que depende del supuesto de largas secuencias de mensajes, de manera que éstos se acerquen a una distribución de frecuencia estable, a medida que las secuencias se aproximan a una longitud infinita (Buckley, 1967).

A partir de sus estudios, Shannon reconoció la correspondencia entre la entropía negativa y la información, afirmando que los contenidos de información de un mensaje aumentan a medida que los elementos de hacen más improbables (Hayles, 1990; Johansen, 1994). La conclusión que es posible sacar de esto, es que a mayor complejidad de un sistema, es decir, a mayor número de estados posibles y de relaciones entre las partes, mayor es la energía destinada a la obtención de información, su procesamiento, almacenaje y comunicación (Millar, en Johansen, 1994).

La asimilación de la información con la entropía negativa, tendrá una serie de efectos, especialmente importantes para las teorías de la complejidad, a ser revisadas más adelante.

c. Teoría de Sistemas

Al hablar de teoría de sistemas, se hace alusión a un campo bastante grande de teorías con distintos nombres. García (1979) reconoce por lo menos siete de estos

nombres, entre ellos, "Sistemas Generales", "Teoría de sistemas" y "Teoría General de Sistemas". Sin embargo, lo que interesa para efectos de este ensayo, es identificar los principios básicos y comunes a estos distintos postulados, de manera de poder resumir los rasgos fundamentales de la Teoría de Sistema que son la base para las teorías de la complejidad.

Si bien una visión más holista de la realidad fue gestándose con el trabajo de muchos autores, desde Montesquieu, Darwin, Spencer, Pareto, Durkheim, Marx y Comte (por nombrar sólo algunos) (Morin, 2005; Rodríguez y Arnold, 1999), varios autores plantean que fue Ludwig Von Bertalanffy, quien dio el gran paso, desarrollando en los años 1920 a 1930 la Teoría General de Sistemas, buscando elaborar una visión organicista y no mecanicista en la biología (Arnold, Sánchez, García, Opazo y Osorio, 1991; García, 1979; Johansen, 1994; Rodríguez y Arnold, 1999).

La Teoría de Sistemas se empieza a aplicar a las ciencias sociales dando respuesta a la conciencia de la insuficiencia de las concepciones analíticas, extremadamente parciales, utilizadas hasta entonces, para dar cuenta de los fenómenos sociales, económicos y políticos. Varios autores plantean que Von Bertalanffy señaló la importancia de considerar al organismo como un "todo" o un "sistema". En esta época habrían confluído, según el mismo Von Bertalanffy, tres corrientes distintas, que permitieron el surgimiento de la teoría de sistemas: la cibernética, la teoría de la información y la teoría de los juegos (García, 1979). Von Bertalanffy (1968) afirmaba que se estaba produciendo un cambio paradigmático de la ciencia, pasando de un modelo reduccionista cartesiano, a una comprensión holista de un todo que es más que la suma de sus partes.

La Teoría General de Sistemas nació con los objetivos de impulsar el desarrollo de una terminología general para describir las características, funciones y comportamientos sistémicos, desarrollar leyes aplicables a todos estos comportamientos y promover la formalización matemática de estas leyes (Arnold, et al, 1991).

Según García (1979), existen pocos aspectos de la teoría de sistemas que son compartidos por todos los autores. En este sentido, una definición muy básica de

sistema, que probablemente sería compartida por todos los autores, es la de Hall y Fagen (en García, 1979, p.49), quienes definen un sistema como un "*conjunto de objetos, además de las relaciones entre los objetos y entre sus atributos*". A esta definición básica se le pueden ir agregando otros componentes. Para Forrester (en García, 1979), las partes del sistema, no solamente se encuentran agrupadas, sino que además operan juntas con un objetivo común.

Un sistema se encuentra compuesto por partes, denominados elementos. Estos elementos se encuentran interrelacionados entre sí, generando una determinada estructura. A su vez, el sistema se encuentra inmerso en un medio, el cual corresponde a las condiciones que influyen sobre su comportamiento (Arnold et al, 1991). Los sistemas pueden recibir la energía necesaria para su funcionamiento y mantención del medio a través de corrientes de entrada o inputs. A su vez, pueden exportar energía al medio a través de la corriente de salida o output (Johansen, 1994).

García (1979) destaca la existencia de distintos tipos de sistemas. Sin embargo, la clasificación más importante es la que distingue entre sistemas abiertos y cerrados, según si estos se encuentran aislados o no del medio. Von Bertalanffy (en Johansen, 1994) define los sistemas cerrados como sistemas que no intercambian energía con su medio, mientras que los sistemas abiertos sí lo hacen. Parsegian (en Johansen, 1994) y Buckley (1967) agregan a la caracterización de los sistemas abiertos el que la naturaleza del intercambio logra mantener alguna forma de equilibrio continuo y, a su vez, que las relaciones con el entorno admiten cambios y adaptaciones. Así, los sistemas abiertos permiten el cambio de la propia estructura para alcanzar un nivel superior o más complejo. La física clásica trabajaba principalmente con sistemas cerrados. Von Bertalanffy (1968) afirma que es por esto que no es posible aplicar a los sistemas vivos, que son sistemas abiertos, las leyes de la física.

Varios autores hacen referencia a los sistemas adaptativos de creciente complejidad. Estos sistemas logran adaptarse a un ambiente potencialmente cambiante, caracterizado por tener gran variedad. El desarrollo para alcanzar niveles superiores depende de la inclusión en la organización de un delineamiento de parte

de la variedad y las constricciones ambientales, sobre una base semi permanente (Buckley, 1967).

Otro tipo de sistemas, es el de los sistemas autoorganizadores de Foerster. Estos sistemas son capaces de organizarse a sí mismos, logrando ir en contra de la tendencia entrópica universal. Es a partir de la relación con el entorno que el sistema logra importar energía y orden (neguentropía). De esta manera, el contacto con el entorno resulta fundamental (Rodríguez y Arnold, 1999).

Varios autores han buscado, desde la sociología, aplicar estos conceptos a los sistemas sociales. Es posible encontrar referencias a lo mismo desde Spencer, quien llevó al extremo la analogía organística, buscando los equivalentes sociales del corazón y del cerebro. También Parsons hizo referencia a los sistemas sociales, definidos por el orden generado a partir de la interdependencia de las partes (Buckley, 1967). El autor más ampliamente conocido por su trabajo en esta área es Niklas Luhmann (cuyo trabajo, sin embargo, no será incluido, debido a que es un tema en sí mismo, que desborda los objetivos de esta investigación).

Los sistemas tienen una serie de características. En la literatura es posible distinguir las siguientes propiedades:

❖ **Totalidad**

Esta propiedad de los sistemas implica una mirada totalmente distinta a la visión analítica-reduccionista clásica, donde los elementos son descompuestos en sus partes elementales para poder ser analizados. Por el contrario, aquí se plantea la necesidad de acercarse a los objetos como un todo (García, 1979; Johansen, 1994). De esta manera, la Teoría General de Sistemas presenta una perspectiva holista e integradora, dándole mayor importancia a las relaciones y a los conjuntos que emergen de estas, asumiendo que las propiedades de los sistemas no son atribuibles a la simple adición de propiedades (Arnold, et al, 1991).

❖ **Sinergia**

Muy asociado a la última característica, la sinergia implica que la suma de las partes es distinta del todo. Como consecuencia, el análisis de una parte aislada, no puede explicar la conducta del todo. De esta manera, es necesario tomar en cuenta la interrelación de las partes y el efecto conjunto generado por estas (Johansen, 1994; Rodríguez y Arnold, 1999). La sinergia lleva a que un conglomerado (suma de partes sin interrelación) se convierta en un sistema, donde el todo efectivamente es más que la suma de las partes (Arnold et al, 1991). A partir de la sinergia es posible llegar al concepto de emergencia. La emergencia de un sistema se refiere a la posesión de atributos que sólo son posibles en el contexto del sistema y que, por lo tanto, no es posible observar en las partes del mismo (Arnold et al, 1991; Von Bertalanffy, 1968).

❖ **Organicismo**

La teoría de sistemas le da una importancia especial a las relaciones entre los distintos elementos de un sistema, o entre estos y su medio, y, por lo tanto, a la organización de los sistemas (Rodríguez y Arnold, 1999). Este concepto no tenía cabida en la ciencia clásica (von Bertalanffy, 1968). A su vez, varios autores afirman que al parecer existe una tendencia natural, inherente a los sistemas, hacia la organización, tendencia que además es independiente de los centros directivos de los mismos. Como ejemplo de esto, se observan los mecanismos homeostáticos de los sistemas, que permiten generar organización la cual no es regulada por ninguna voluntad (Johansen, 1994).

❖ **Recursividad**

La recursividad de los sistemas quiere decir que estos, siendo objetos sinérgicos, están compuestos a su vez por objetos sinérgicos. De esta manera, es posible hablar de supersistemas, sistemas y subsistemas (Johansen, 1994). Morin (2001) afirma que los sistemas son a su vez sistemas de sistemas. Por ejemplo, el ser vivo es un sistema que participa en un sistema de reproducción, en un eco-sistema, entre

otros. Estos distintos sistemas tienen propiedades que los convierten en totalidades y, por lo tanto, a pesar de ser parte de un supersistema mayor y de estar compuesto de subsistemas, son elementos independientes (Johansen, 1994).

❖ **Isomorfismo**

Según Bertalanffy (en García, 1979) existirían correspondencias entre los principios que rigen el comportamiento de distintas entidades, que en el fondo, son muy distintas. Gracias a esta propiedad, es posible hablar de una teoría general de sistemas, que sea transversal a las distintas ciencias (von Bertalanffy, 1968). De esta manera, varios autores plantean la necesidad de crear una ciencia interdisciplinaria y, es en este mismo sentido, que la Teoría General de Sistemas se presenta como una herramienta de corte horizontal que atraviesa los distintos campos del saber (Johansen, 1994). Von Bertalanffy (1968) plantea que hasta la brecha entre ciencias naturales y sociales se estrecha, en el sentido de sus similitudes estructurales.

❖ **Complejidad del sistema**

La complejidad tiene que ver con los niveles de organización del sistema (Johansen, 1994). De esta manera, un sistema es más complejo cuando aumenta el número de sus componentes, la cantidad de interrelaciones y de la cualidad de las relaciones con el medio. La complejidad supone diversidad (Arnold et al, 1991; García, 1979). Según Johansen (1994), al ir pasando de subsistemas a sistemas y a suprasistemas, se va pasando de estados de organización relativamente simples a otros cada vez más avanzados y complejos. Según Boulding (en Johansen, 1994), es posible jerarquizar los sistemas desde los más simples, como las estructuras estáticas, hasta los más complejos, como los seres humanos y los sistemas sociales. También es posible llegar al sistema que engloba todos los demás: el sistema ecológico.

❖ **Equifinalidad y Multifinalidad**

En el caso de los sistemas cerrados, si se alteran las condiciones iniciales, el estado final cambiará también. Esto no ocurre en los sistemas abiertos. En estos, es posible alcanzar el mismo estado final partiendo de distintas condiciones iniciales y por diferentes caminos (Von Bertalanffy, 1968). En este sentido, la equifinalidad quiere decir que, es posible alcanzar el mismo estado final a partir de condiciones iniciales distintas, gracias a la interacción con el medio (Arnold, et al, 1991; Buckley, 1967; García, 1979; Rodríguez y Arnold, 1999). A su vez, la multifinalidad quiere decir que condiciones iniciales similares conducen a efectos finales diferentes (Buckley, 1967). Según Buckley (1967), estos conceptos reemplazan los conceptos clásicos de causalidad.

❖ **Equilibrio**

Según García (1979), los sistemas viajan en el tiempo tratando de mantener su identidad y recuperando el estado óptimo de sus relaciones con el medio. Frente a cambios externos, el sistema aminora los impactos, desarrollando programas pre establecidos que permiten una serie de reacciones internas del sistema que lo defienden de las variaciones del ambiente. Por lo tanto, los sistemas tienen la propiedad de autocontrol y autorregulación, permitiendo un equilibrio homeostático (Johansen, 1994). Sin embargo, si bien existen fuerzas que permiten resistir a los cambios rápidos, también existen otras fuerzas que buscan generar cambios, pero en procesos lentos y evolutivos. Por lo tanto, es posible que exista evolución en equilibrio (Johansen, 1994). De esta manera, Buckley (1967) afirma que la homeostasis no implica una condición que no puede variar, pero sí que es relativamente constante. Para mantener el equilibrio en sistemas abiertos, es necesario importar recursos del ambiente (Arnold et al, 1991). En general, los sistemas mecánicos poseen una estructura relativamente estable, en la cual las partes no se ven afectadas de manera permanente por su condición de ser parte del sistema. Sin embargo, al aumentar la complejidad de los sistemas, los componentes interrelacionados presentan una organización cada vez más compleja e inestable. En estos casos, los rasgos de los componentes resultan más fácilmente alterables por

los movimientos del sistema. No obstante, en niveles más altos de complejidad de los sistemas, las relaciones de las partes cobran mayor flexibilidad, generando complejidad organizada (Buckley, 1967).

❖ **Identidad**

Al mantenerse los sistemas en el equilibrio a lo largo del tiempo, logran preservar su identidad. De hecho, los sistemas son posibles de ser reconocidos porque están cohesionados, se prescriben a sí mismos reglas de actividad y asimilan su experiencia por medio de procesos autorreguladores de aprendizaje, adaptación y evolución (García, 1979). Sin embargo, el tema de la identidad de los sistemas lleva ineludiblemente al cuestionamiento por las fronteras de los mismos. Según Johansen (1994), resulta bastante difícil fijar las fronteras de los sistemas. Una de las causas más importantes es el intercambio constante entre sistemas y el mundo exterior. De hecho, Buckley (1967) afirma que mientras más abiertos sean los sistemas, la estructura es más flexible y la distinción entre los límites y el medio es cada vez más arbitraria, sujeta a la decisión del observador.

❖ **Diferenciación**

Al desarrollarse un sistema, este se especializa funcionalmente, como un proceso de elaboración de partes. Las pautas globales difusas se van reemplazando por funciones especializadas. De esta manera, se van imponiendo restricciones y especializaciones a los componentes (Rodríguez y Arnold, 1999)

2.4 Las Generalidades de las Teorías de la Complejidad

Es difícil afirmar si las nuevas teorías de la complejidad son parte de un mismo y único paradigma. De hecho, Mier (2002) habla de la existencia de teorías de la complejidad, dado que no existe un carácter unitario ni consistente entre las mismas, ni una propuesta teórica acotada, dotada de un objeto específico. Sin

embargo, a primera vista queda claro que hay algo que sí tienen en común: todas parten de las mismas críticas a la ciencia clásica. Las anomalías presentadas, son la base desde la cuál surgen las críticas, sin embargo, no son las únicas.

Para Morin (2005) la complejidad no elimina las características de la ciencia clásica, más bien entra en juego en aquellos puntos donde el pensamiento simplificador no logra dar una explicación. Por lo tanto, integra en si mismo el orden, la claridad, la distinción y la precisión del conocimiento. Según Morin (2001) la incorporación de lo no simplificable, de lo incierto y lo confuso, si bien puede parecer una regresión desde el punto de vista de la ciencia clásica, en realidad es inseparable del avance del conocimiento. A partir de esto, Morin propone cambiar el universo frío, de movimientos perpetuos, de orden impecable y de equilibrio por uno caliente, con movimientos irreversibles, de orden mezclado con desorden, de gasto y de desequilibrio.

Al estudiar a los distintos autores de la complejidad, se observan una serie de temas generales, que aparecen prácticamente en todos ellos, así como temas propios de cada uno, los cuales representan un tipo de síntesis de sus respectivas posturas. Dada la complejidad de presentar temas tan generales, por un lado, y tan específicos por otro, se ha optado por presentar las distintas temáticas de manera segmentada. En una primera parte, se presentarán los principales temas tratados por la mayoría de los autores de la complejidad. En este punto se intentará dar cuenta de los pilares de la complejidad, mientras se discutirá sobre las similitudes y diferencias entre los distintos autores con respecto a los mismos. En una segunda parte, se tratarán aquellos constructos que son propios de distintos autores y escuelas. El hecho de utilizar esta estructura y no una temática, por autor, permite evitar repetir en cada capítulo los mismos temas. De esta manera, se podrán comparar las distintas visiones sobre los mismos temas, así como distinguir las posturas específicas de los autores y escuelas. A su vez, a partir de este análisis será posible derivar una definición de complejidad que pueda incorporar lo fundamental de los distintos autores.

El análisis de lo común de los autores de la complejidad permite, a su vez, discernir si es posible hablar de un paradigma unitario de la complejidad o si, más bien se trata de teorías de la complejidad segmentadas.

A continuación se presentan los temas más relevantes de las teorías de la complejidad:

❖ **Visión sistémica y holista**

Como ya se había afirmado anteriormente, la Teoría de Sistemas es uno de los pilares de la complejidad. Sin embargo, es necesario destacar que su importancia no radica solamente en introducir en el debate una serie de temáticas necesarias para la aparición de la complejidad, sino más bien, es parte del constructo mismo de la Complejidad.

En términos generales, los teóricos de la complejidad asumen que los problemas no pueden ser entendidos de manera aislada. Los problemas se encuentran interconectados y son interdependientes entre sí (Capra, 2003a). Esto lleva a Capra a afirmar que el nuevo paradigma podría llamarse visión holista del mundo, ya que estudia el todo integrado, más que coleccionar sus partes. De esta manera, propone una ecología profunda, la cual pueda reconocer la interdependencia entre los fenómenos y asume que los individuos y las sociedades se encuentran inmersos en los ciclos de la naturaleza. Esta ecología no separa a los humanos de su entorno natural, como lo ha hecho la ciencia clásica. De hecho, el autor afirma que, dado que los sistemas vivos son redes a los distintos niveles, es necesario entender la trama de la vida interactuando en forma de red con otros sistemas. Esto último es fundamental en muchos temas que se irán revisando a lo largo de este ensayo.

También Morin (1983) plantea que la nueva ciencia debe ser la ecología, según la cual todos los fenómenos han de ser asumidos en su relación con el entorno. La ecología, según el autor, es la *"ciencia de las interacciones combinatorias/organizadoras entre cada uno y todos los constituyentes físicos y vivientes de los ecosistemas"* (Morin, 1983, p. 34). Por lo tanto, propone romper con la mirada rígida que aísla a los seres de su entorno o los reduce al mismo. La ciencia de la ecología es una nueva ciencia que no aísla a su objeto de su contexto como lo hacía la ciencia clásica. Según el autor (p. 33), la noción de ecosistema es fundamental en cuanto permite concluir que *"las interacciones entre vivientes, al conjugarse con los estreñimientos y posibilidades que proporciona el biotipo físico"*

(y al retroactuar sobre éste) organizan precisamente al entorno en sistema". Antes de la aparición de la ecología, solamente se conocían las dimensiones especie e individuo, sin tomar en cuenta al entorno. La existencia debe considerarse en base a la relación de los seres vivos con su entorno, por medio de la adaptación y la selección.

Muy ligado a lo anterior, Prigogine (en Zúñiga, 2003) afirma que con el desarrollo de la sociología se logra incorporar el entorno al modelo. Esto permite generar una visión más holista del mundo y tomar en cuenta las inestabilidades producidas por el medio.

La visión sistémica y holista es compartida explícita o implícitamente por todos los autores de la complejidad. De hecho, se podría decir que esta es la piedra fundamental de la misma.

❖ **Emergencia**

El concepto de emergencia es uno de los más relevantes de la Complejidad, utilizado por la mayoría de los autores, y se podría decir que es un producto directo de la Teoría de Sistemas. Según esta última, el todo posee propiedades que no se encuentran en sus partes. Estas cualidades emergen desde las interacciones y relaciones entre las partes (Capra, 2003a). Morin (2001) afirma que la emergencia son propiedades de un sistema que tienen un carácter de novedad con respecto a las propiedades de los componentes considerados de manera aislada. En consecuencia, la naturaleza del todo es siempre distinta a la suma de las partes. Por lo tanto, un sistema no puede ser entendido solamente por medio del análisis de sus partes (Capra, 2003a). Según Byrne (1998) la teoría de la complejidad rechaza la validez de las estrategias analíticas, en las cuales el todo se reduce a las partes. En complejidad se trabaja con propiedades emergentes. También los autores del Instituto de Santa Fe (Lewin, 2002; Waldrop, 1992) afirman que la interacción de componentes individuales a partir de los cuales emergen propiedades globales, implica que estas últimas no pueden ser predichas por medio del análisis de sus partes.

Morin (1984) va un poco más allá, afirmando que una organización es capaz de mantener un conjunto dado que dispone de cualidades emergentes porque retroactúa las cualidades emergentes del todo a las partes.

Villanueva (2006) afirma que existe un principio hologramático, según el cual no solamente la parte está en el todo, sino que el todo está en la parte. Las relaciones entre ambos son complejas. De esta manera, las uniones de las partes constituyen el todo, el cual a su vez retroactúa sobre los elementos.

Según Morin (1984; 2001; 2005) la relación entre el todo y las partes se puede describir según los siguientes principios:

- **El todo es más que la suma de las partes que lo constituyen.** El conocimiento simple no ayuda a conocer las propiedades del conjunto. El sistema es más que las partes consideradas de manera separada: es organización, cualidades y propiedades nuevas que emergen de la organización global
- **El todo es, entonces, menos que la suma de las partes.** Esto quiere decir que las cualidades de las propiedades, unidas a las partes consideradas aisladamente, desaparecen en el seno del sistema. Las cualidades de los componentes se encuentran inhibidas por el todo.
- **El todo es más al mismo tiempo menos que la suma de las partes.**

Las relaciones entre el todo y las partes se encuentran mediatizadas por las interacciones, las cuales serán analizadas más adelante.

También la emergencia es un concepto asumido por todos los autores de la complejidad. Esto se puede observar en el hecho de que estos no utilicen estrategias analíticas en sus estudios, sino más bien busquen analizar como los componentes de un sistema interactúan para dar cuenta del todo.

❖ **Retroalimentación**

También muy cercano a la Teoría de Sistemas y especialmente a la Cibernética, se encuentra el concepto de Retroalimentación. La Retroalimentación hace referencia a la capacidad de un sistema de regularse a sí mismo por medio de la reinserción en él de los resultados de su actividad (García, 1979). Wiener (1969), desde la Cibernética, define la retroalimentación como una regulación de una máquina de acuerdo a su funcionamiento real y no respecto a lo que se espera de ella.

Según Capra (2003a), varios autores plantean que una de las características fundamentales de los sistemas abiertos es su propia autorregulación. Según esto, los sistemas vivos se organizan en un proceso causal circular cerrado, el cual les permite evolucionar manteniendo su circularidad.

Morin (2001) utiliza el concepto de bucle retroactivo, sacando la idea de la cibernética. De esta manera, el bucle hace referencia a procesos retroactivos que aseguran la existencia y constancia de la forma. El bucle retroactivo es también recursivo, esto quiere decir que se produce a sí y se regenera. La generatividad implica que la producción produce al productor que la produce. Este concepto es fundamental para la conceptualización que el autor hace acerca de la dinámica de autoorganización, que se analizará más adelante.

También Maturana y Varela (1994) tienen un concepto propio para denominar procesos de retroalimentación, esto es, la autopoiesis, que significa que los sistemas se producen a sí mismos. Esto se analizará más adelante, en el capítulo sobre la autopoiesis.

Los autores del Instituto de Santa Fe, al hablar de los sistemas adaptativos, también hacen referencia a sistemas que utilizan información del medio para adaptarse al entorno (Lewin, 2002; Waldrop, 1992).

Varios autores (Briggs y Peat, 1989; Johansen, 1994; Morin, 2001) distinguen entre dos tipos de retroalimentación: retroalimentación negativa y positiva. La retroalimentación negativa ocurre cuando la información de retroalimentación advierte de desviaciones en el camino y, de esta forma, el sistema puede tomar

medidas correctivas para hacer retornar al sistema a su camino original. En este contexto, se puede hablar de la homeostasis, la cual es un proceso que actúa para mantener el estado estacionario del organismo, a despacho de perturbaciones exteriores (Morin, 2001). La retroalimentación positiva, por su parte, ocurre cuando la comunicación de retroalimentación va dirigida a apoyar la dirección inicial, amplificando la desviación. La retroalimentación positiva lleva normalmente a la inestabilidad del sistema (Van Gigch, en García, 1979).

Por lo tanto, también en el caso de la retroalimentación, se observa que este es un concepto transversal a los autores de la complejidad y que no existen discrepancias en la manera de analizarla.

❖ **El segundo principio de la termodinámica y la entropía**

Los tres conceptos analizados hasta el momento (la visión sistémica, la emergencia y la retroalimentación) son propios de la Teoría de Sistemas y la Cibernética. Estos conceptos han sido adoptados por los teóricos de la complejidad en la construcción de las teorías de la complejidad. Sin embargo, es posible afirmar que desde el segundo principio de la termodinámica, se empiezan a construir nociones propias de la complejidad. Este principio es fundamental, dado que es a partir de este que se empiezan a cuestionar una serie de aspectos, como la entropía, la noción del tiempo, la dialéctica entre orden-desorden y la autoorganización. Dado que estos son temas pilares para este trabajo, es necesario referirse primeramente al segundo principio de la termodinámica.

Según el primer principio de la termodinámica, la energía es una entidad indestructible, dotada de la capacidad de transformación. Basado en este principio, el universo sería autosuficiente y eterno. Sin embargo, el segundo principio, esbozado por Carnot y formulado por Clausius, si bien no se contradice con el primer principio, afirma que la energía se va degradando. La energía tiene una disminución irreversible de la capacidad de transformarse y efectuar trabajo. A esta disminución, Clausius le denominó entropía (Morin, 2001). De esta manera, en todo sistema cerrado, que no se alimenta con energía exterior, las transformaciones se encuentran necesariamente acompañadas de un aumento de entropía. Esto ocurre

porque, según la misma ley, los sistemas tienen una tendencia a alcanzar su estado más probable y este es el caos, el desorden y la desorganización. Como correlato, la degradación irreversible no puede más que aumentar hasta un máximo, que es el estado de homogeneización, el olvido de toda disimetría inicial y el equilibrio térmico. De esta manera, la probabilidad alcanza el máximo al llegar a la uniformidad. Esta situación ha llevado a muchos autores a plantear que el universo, como sistema, irá pasando de estados más organizados a otros menos organizados, hasta llegar al caos final (Arnold et al, 1991; Capra, 2003a; Johansen, 1994; Prigogine, 1997a; 2004; Prigogine y Stengers, 1990; Wiener, 1969).

En el caso de los sistemas abiertos, la entropía puede ser liberada hacia el medio ambiente, logrando mantener niveles relativamente bajos de entropía. A esta entropía negativa que extraen desde el medio, se le denominó neguentropía, lo que es un sinónimo de decir que extraen orden (Buckley, 1967; Johansen, 1994; Von Bertalanffy, 1968). Esta situación permite a los sistemas abiertos, como los vivos, a mantenerse en un estado de alta improbabilidad (Rodríguez y Arnold, 1999; Von Bertalanffy, 1968). Wiener (1969) explica esta situación como enclaves locales o islas, cuya dirección parece opuesta a la del universo como un todo, los cuales presentan una tendencia temporal y limitada de aumentar la complejidad de su organización. Según el autor, la existencia de estas islas lleva a algunos a pensar que existe el progreso. El medio por el cual estos enclaves logran resistirse a la corriente general es la homeostasis.

Otro análisis relevante con respecto a la entropía tiene que ver con su paralelo con la información. Esta última es asumida como neguentropía, en el sentido de que permite disminuir la incertidumbre o el caos, combatiendo la entropía (Johansen, 1994; Morin, 2005; Prigogine, 1997). La información, en comparación con la distribución al azar, es un estado improbable. De esto resulta que la entropía negativa o la información sea una medida de orden o de organización (Von Bertalanffy, 1968). De hecho, Arnold et al (1991) plantean que la información es la corriente neguentropica más importante de que disponen los sistemas complejos.

La entropía es uno de los conceptos más utilizados por los autores de la complejidad. Es a partir de este concepto que aparecen las nociones de

autoorganización, que se analizarán más adelante. Por lo tanto, es posible afirmar que la entropía se encuentra entre los supuestos básicos de la complejidad.

❖ **La flecha del tiempo**

Tal vez la consecuencia más inmediata del segundo principio de la termodinámica –y a la cual Prigogine le otorga una importancia sin igual– es el cambio de la noción de tiempo.

Prigogine (1997a) explica que desde Galileo el tiempo ha sido considerado como reversible. Esto quiere decir que existe una simetría entre pasado y futuro. Esta noción fue aceptada no sólo por toda la física tradicional, sino también por la mecánica cuántica y la relatividad. Hasta Einstein afirmaba que la irreversibilidad era sólo una ilusión (Lasky, 2002; Prigogine, 1997b; 2004). Asumir que el tiempo es reversible implica, a su vez, que el universo es uno, infinito e inmóvil. Por otra parte, implica que la descripción de la física tradicional en términos de trayectorias, permite la predicción determinista. Dadas ciertas condiciones iniciales, sería posible predecir con exactitud toda la trayectoria (Nicolis y Prigogine, 1997; Prigogine, 2004). Las leyes de Newton, que son las más representativas de este paradigma, son reversibles en el tiempo, dado que no cambian con la inversión del tiempo futuro o pasado (Prigogine, 1997b).

Sin embargo, Prigogine (1997a; 1997b) afirma que desde el desarrollo de la física de no equilibrio y de la dinámica de los sistemas dinámicos inestables, los cuales se asocian a la idea de caos, es necesario volver a revisar la noción del tiempo con la que trabajamos. Según el autor, el cuestionamiento de la flecha del tiempo se termina de confirmar con la termodinámica y la introducción de la entropía. Los procesos estudiados por la termodinámica son procesos irreversibles, dado que poseen una dirección privilegiada en el tiempo, a diferencia de procesos reversibles como el movimiento del péndulo sin fricción. Por lo tanto, dado que existen más posibilidades de que las cosas estén mezcladas a que estén separadas, la entropía indica la dirección del futuro. A modo de resumen, es posible afirmar que si las cosas se dejan al azar, un sistema cerrado evolucionará hacia el desorden, el cuál tiene más probabilidades (Nicolis y Prigogine, 1997; Prigogine, 1997a).

Boltzmann (en Capra, 2003a; Morin, 2001; Nicolis y Prigogine, 1997; Prigogine, 1997b) presentó un esquema para demostrar la irreversibilidad. Si se consideran dos cajas conectadas por un conducto, en una de las cuales hay muchas partículas y en la otra pocas, con el paso del tiempo el número de partículas se igualaría progresivamente. Esto, según Boltzmann, es la irreversibilidad, donde ocurre un movimiento desde un estado improbable hacia un estado probable. De esta manera, Boltzmann demostró que la entropía se observa en la evolución de una población de moléculas. A su vez, concluyó que no es posible analizar esta evolución con respecto a un individuo, sino a una población. Por lo tanto, la entropía es un concepto estadístico.

Prigogine (1997) concluye con respecto a la irreversibilidad, que estos procesos son tan reales como los reversibles y que estos desempeñan un papel constructivo en la naturaleza, realizando las estructuras más delicadas y complejas. De esta manera, según el Prigogine y Stengers (Prigogine, 1997; Prigogine y Stengers, 1990), la irreversibilidad permite la evolución del universo, así como la flecha del tiempo.

❖ **Orden, Desorden y Organización**

Los supuestos básicos de la complejidad –una visión sistémica, la emergencia, la retroalimentación; así como el segundo principio de la termodinámica y la flecha del tiempo- son asumidos prácticamente por todos los autores como la base desde la cuál plantear sus teorías. De hecho, algunos se dedican más y otros menos a la discusión en torno a estos temas, sin embargo, no existen grandes diferencias entre ellos. Por ejemplo, si bien el teórico de la flecha del tiempo es Prigogine, llama la atención la inmensa cantidad de referencias de todos los demás autores sobre este tema.

El debate en torno a orden, desorden y organización (lo que corresponde a una tríada presentada por Morin (1984), puede ser definido como la piedra angular de la Complejidad. De hecho, se puede argumentar que es esto lo realmente nuevo y propio de las teorías de la complejidad.

La pregunta con respecto al orden tiene su fundamento en la siguiente problemática: *¿cómo es posible, si el universo atraviesa un proceso de desintegración continua, que, sin embargo, se generen estructuras, y, por lo tanto, orden?* Esta pregunta aparece explícita o implícitamente en los textos de todos los autores de la complejidad (Lewin, 2002; Morin, 2001; 2005; Prigogine, 2004; Waldrop, 1992). A su vez, es en torno a esta pregunta, que los autores definen sus teorías de la complejidad.

Tal vez la principal novedad de la complejidad es asumir que Orden y Desorden no son contradictorios, sino complementarios (Balandier, 1988; Briggs y Peat, 1989; Byrne, 1998, Morin, 2001; 2005; Nicolis y Prigogine, 1997). Según Morin (2001; 2005), la ciencia clásica ignoró la dispersión y la degradación. De hecho, plantea que hicieron falta decenios para comprender que orden y desorden, si bien son enemigos el uno del otro, cooperan en la organización del universo. El universo se organiza desintegrándose, es por esto que la tríada fundamental es orden/desorden/organización.

La complementariedad entre orden y desorden hace alusión al hecho de que es posible la creación de orden desde el desorden. El principio mecánico era el del orden desde el orden, mientras que para von Foerster (en Capra, 2003; Morin, 1984; 2001) el concepto fundamental es el de orden desde el ruido, con lo que se asume que el sistema no importa solamente orden desde su entorno, sino que también absorbe materia rica en energía, para aumentar su orden interno. A su vez, el concepto de la estadística es el del orden desde el desorden y desorden desde el orden. Gunther (en Morin, 1984) introduce la síntesis orden desde (orden+desorden).

Para Morin (1983), el desorden es importante en cuanto a partir de un accidente, puede ocurrir que la tendencia organizadora aproveche de crear una unidad superior. De esta manera, el origen de la vida necesariamente tiene que incluir agitaciones, turbulencias y encuentros aleatorios. De hecho, todas las innovaciones comportan eventos aleatorios (Morin, 1980; 1983). También Schrödinger y Prigogine (en Capra 2003a; 2003b; Prigogine, 1997) afirman que en condiciones muy inestables pueden surgir nuevas estructuras, que pueden llevar a estructuras de orden superior. De

esta manera, sería imposible que se diera vida si solo hubiera orden, ya que no habría innovación. Sin embargo, también sería imposible si hubiera puro desorden, ya que no habría ninguna estabilidad sobre la cual fundar esta organización. En consecuencia, las organizaciones necesitan orden y desorden (Morin, 2005).

Prigogine y Stengers (1990) afirman que ya no importan solamente las situaciones estables y las permanencias, sino también las evoluciones, las crisis y las inestabilidades. De esta manera, para Morin (2001) el desorden que existe en el universo cobra importancia en cuanto a que es un desorden constitucional, de génesis y de creación. Por lo tanto, Morin plantea la posibilidad de existencia de un universo que forme su orden u organización en la turbulencia, la inestabilidad, la desviación, la improbabilidad y la disipación energética. Esta reflexión critica a su vez la evolución darwinista, según la cual toda innovación se debe exclusivamente a las mutaciones. Capra (2003a; 2003b) afirma que es necesario agregar a estas el avance constante de la vida hacia la novedad.

También para la Teoría del Caos (que se analizará en mayor profundidad a más adelante), es necesario incorporar el caos y el desorden al estudio de la realidad. Las turbulencias, las irregularidades y la imprevisibilidad se encontrarían por doquier y, sin embargo, han sido asumidos por la ciencia clásica como ruido y como contingencias aleatorias exteriores (Balandier, 1988; Briggs y Peat, 1988; Hayles, 1990). Balandier (1988) afirma que la física debe asumir que las nociones de orden y equilibrio se vinculan con la de desorden. De hecho, para Hayles (1990), el caos es aquello que hace posible el orden, y que este es "el vientre de la vida, no su tumba". Para Balandier (1988) el acrecentamiento del desorden permite la formación de un nuevo orden, y de esta manera, de un aumento de la complejidad.

Un tema interesante relacionado a la Teoría del Caos es la existencia de lo que varios autores denominan "Caos determinista". Según esto, el caos muestra que dentro de un área determinada, el desorden es compatible con el orden (Nicolis y Prigogine, 1997). Según Prigogine (1997), el caos determinista se encuentra definido por ecuaciones que si bien engendran un comportamiento aleatorio, son tan deterministas como las leyes de Newton. Sin embargo, es necesario destacar que las leyes del caos se sitúan en el nivel estadístico. La dinámica formulada a nivel estadístico no tiene equivalente en términos de trayectoria. De esta manera, las

condiciones iniciales no pueden ser representadas por un punto en el espacio de fases, sino más bien, corresponde a una región descrita por una distribución de probabilidad.

También Morin (2005) afirma que la complejidad no debe incluir solamente al desorden, sino también incertidumbre, indeterminaciones y fenómenos aleatorios. El azar constituye una dimensión presente en todas las formas de desorden. El origen de la vida no puede concebirse sin encuentros aleatorios, toda innovación evolutiva comporta azar, el ser viviente genera azar (Morin, 1980). A su vez, la indeterminación del comportamiento individual de las partículas microfísicas se ubica en el nivel de los individuos. Por eso, este está sometido al azar. Por lo tanto, hay imprecisión en las mediciones y esta solo puede ser absorbida a nivel estadístico. Por lo tanto, la complejidad no puede ser separada del azar (Morin, 1980). De hecho, Morin (1984) afirma que el determinismo mecánico se ha flexibilizado y enriquecido hasta llegar al probabilismo moderno.

A su vez, para muchos de los autores de la complejidad, orden y desorden no pueden ser entendidos sin el concepto de **organización**. Para Morin (1984), la organización es la columna vertebral de toda teoría sobre las cosas y los seres. Es por esto que insiste en la necesidad de unir orden, desorden y organización. El autor (1977, p. 126) define la organización como: *"la disposición de relaciones entre componentes o individuos que produce una unidad compleja o sistema, dotado de cualidades desconocidas en el nivel de los componentes o individuos. La organización une de forma interrelacional elementos o eventos o individuos diversos que a partir de ahí se convierten en los componentes de un todo"*. Morin afirma que la organización puede ser asumida como un islote de neguentropía. De esta manera, la neguentropía saca la entropía al exterior, como subproducto de su reino en el interior de un sistema.

La organización tiene, según Morin (1984) dos aspectos. Por un lado, la organización permanente de un sistema que tiende a la desorganización. Por el otro, la reorganización permanente de sí, esto es, la auto-re-organización. De esta manera, tomando el concepto de organización y uniéndolo a la retroalimentación, es posible entender porque estos autores le otorgan tal importancia al concepto de Autoorganización. Capra (2003^a, p.103) define la autoorganización como la

"aparición espontánea de nuevas estructuras y nuevos modos de comportamiento en sistemas lejos del equilibrio, caracterizada por bucles de retroalimentación internos y descrita matemáticamente en términos de ecuaciones no-lineales". La autoorganización implica la combinación de no-equilibrio, la irreversibilidad, los bucles de retroalimentación y la inestabilidad (Capra, 2003a).

Capra (2003a) afirma que el patrón de la vida es un patrón capaz de autoorganizarse. Si bien un estado inicial de una red puede ser escogido al azar, luego de un tiempo emergen patrones ordenados. A esta emergencia de patrones, el autor le denomina autoorganización. La autoorganización incluye la capacidad de crear nuevas estructuras.

Morin (2005) afirma que fue con von Neumann con quien apareció por primera vez el concepto de complejidad asociado a la autoorganización. De esta manera, la reproducción de sí aparece con la problematización de von Neumann (en Morin, 1984), sobre la teoría de los "self producing automata". Los autómatas artificiales se degradan desde que empiezan a funcionar, mientras que los seres vivos pueden resistir la degradación, por medio de la generación de sus componentes. De esta manera, tienen la originalidad de funcionar con desorden, auto-re-organizándose continuamente. De hecho Morin (2005) concluye que la única manera de combatir la degeneración es la regeneración permanente. Esto implica el uso de estrategias determinadas tomando en cuenta una situación aleatoria y que permita las modificaciones en función de las informaciones provistas durante el proceso. De esta manera, la autoorganización implica plasticidad. Los seres vivos pueden autoorganizarse dado que son sistemas abiertos que operan lejos del equilibrio y que importante constantemente materia y energía del medio.

Para Morin (1980) la autoorganización tiene que ver con la adaptación de los seres vivos a su entorno. La idea de adaptación implica pensar la vida en términos flexibles y plásticos, esto es, tener la capacidad de adaptarse y volver a adaptarse de manera diversa. Existe un juego entre el todo y las partes, en el sentido de que cada ser viviente utiliza al medio para sus propios fines, al mismo tiempo que el medio utiliza los actos egocéntricos de las partes para sí mismo. El individuo funciona con el ecosistema. Su auto organización forma parte de la eco-organización. La organización viviente debe referirse al mismo tiempo a los estados internos y a

las condiciones externas para asegurar su organización interna y su comportamiento externo. Para hacer esto, utiliza la computación, la cual es un complejo organizador/productor de carácter cognitivo. La computación viviente permite la organización y reproducción del ser (Morin, 1988).

También Biebracher, Nicolis y Schuster (en Prigogine, 1997a) afirman que el orden sólo puede mantenerse por medio de su autoorganización, porque los sistemas autoorganizadores permiten la adaptación a las circunstancias ambientales. De hecho, Prigogine y Stengers (1990) estudian los sistemas dinámicos alejados del equilibrio y concluyen que es solamente en esta situación que se puede generar orden, dado que solamente aquí se generan correlaciones. Esto se analizará más adelante, al hablar de los sistemas disipativos de Prigogine.

Para los autores del Instituto de Santa Fe (Lewin, 2002; Waldrop, 1992), los sistemas complejos tienen la propiedad de autoorganizarse. Los autores denominan a esta autoorganización orden espontáneo. Todas las investigaciones del Instituto de Santa Fe se basan en el supuesto de la autoorganización. También este tema será analizado más en profundidad en el capítulo sobre el Instituto de Santa Fe.

También para Maturana y Varela (1994), la autoorganización es un tema fundamental. Para estos autores el concepto básico es el de la autopoiesis, según la cual existen sistemas que se crean a sí mismos por medio de la elaboración de los componentes que los definen.

Tal vez el autor que llevó el tema de la autoorganización más al extremo fue Lovelock con su Teoría Gaia, según la cual el planeta Tierra, como un todo, es un sistema autoorganizador vivo. Lovelock explicaba que los gases que se encuentran en la atmósfera son capaces de reaccionar entre sí, así como de coexistir en altas proporciones. Por lo tanto, se origina una mezcla de gases lejos del equilibrio. Este estado, según el autor, es consecuencia de la presencia de vida en la tierra, tema que no se da en Marte. Se preguntó si sería posible que la vida en la tierra estuviese regulando la atmósfera, de manera que fuera favorable para todos los organismos. Esto ocurre, por ejemplo, con la temperatura de la tierra, que logra mantenerse constante. De esta manera, la tierra, al igual que los organismos vivos, lograría autorregularse para sobrevivir. Lovelock, junto con Margulis, distinguieron una serie

de bucles de retroalimentación que permitían la autorregulación del planeta (Capra, 2003a).

Morin (1983) hace un análisis bastante parecido al afirmar que el ecosistema se encuentra en un proceso de desorganización/reorganización permanente. El orden producido por la eco-organización permite tolerar una enorme cantidad de desorden. La eco-organización tiene la cualidad de reorganización por medio del efecto de desorganizaciones, lo que le permite evolucionar ante la irrupción perturbadora de lo nuevo y por medio de esto, la vida no solo sobrevive, sino que se desarrolla, o, más bien, se desarrolla para sobrevivir.

Es posible observar que existe un común acuerdo en que el desorden debe ser complementario a la idea de orden de la ciencia clásica. De hecho, esto es afirmado por todos los teóricos de la complejidad. Sin embargo, solamente para algunos cobra relevancia el tema de la organización y, especialmente, el de la autoorganización.

❖ **Interacciones**

Uno de los conceptos fundamentales para explicar la creación de orden desde el desorden es el de interacción.

Según Byrne (1998), la interacción es lo que ocurre cuando el efecto de múltiples variables no es aditivo. Por lo tanto, esto se relaciona estrechamente con el concepto de No-linealidad, que será analizado a continuación.

Para Morin (2001), las interacciones juegan un papel esencial. Las interacciones suponen que los elementos pueden encontrarse, que existen condiciones de encuentro –esto es, de agitación, turbulencias, entre otros- que obedecen a determinaciones/constreñimientos que dependen de la naturaleza de los elementos. Las interacciones, en algunos casos dan lugar a fenómenos de organización. Por lo tanto, para que haya organización es necesario que haya interacciones, y, por lo tanto, desorden.

Lo interesante de las interacciones, según el autor, es que una vez que se constituyeron como organizaciones, sus reglas de juego dan la impresión de ser leyes de la naturaleza. A su vez, las interacciones son, por lo tanto, el vínculo entre el desorden, el orden y la organización.

❖ **Linealidad**

El manejo de ecuaciones no lineales exige el uso de técnicas matemáticas que no eran conocidas hasta hace algún tiempo. Por esta razón, se realizaban aproximaciones lineales y nunca se hacían análisis fuera de esta linealidad. Según Briggs y Peat (1989), por medio de esto fue posible preservar el viejo hechizo reduccionista.

Los sistemas lineales son sistemas que presentan poca interacción entre las partes y, por lo tanto, no presentan sorpresas (Martínez, 1997). En cambio, en sistemas no lineales, una causa mínima puede desencadenar efectos muy grandes, que no guardan relación con la amplitud del suceso desencadenado. Esto último implica que exista una incongruencia entre causa y efecto, pudiendo, por ejemplo, una pequeña causa, dar origen a un efecto grande (Capra, 2003^a; Briggs y Peat, 1989; Hayles, 1990). La no linealidad, con limitaciones de no equilibrio, admite múltiples soluciones, posibilitando la diversificación en el comportamiento de un sistema (Nicolis y Prigogine, 1997). La predicción en este contexto se vuelve mucho más difícil (Briggs y Peat, 1989; Lewin, 2002; Waldrop, 1992).

El cambio paradigmático ha tenido mucho que ver con el reconocimiento de que la naturaleza es inexorablemente no-lineal. De hecho, la teoría de los sistemas dinámicos es la primera matemática que permite el trabajo pleno de fenómenos no lineales (Capra, 2003a). Según Nicolis (en Byrne, 1998), hay una importante cantidad de fenómenos que no son lineales. Byrne (1988) sugiere que esto incluye a la mayor parte de los aspectos sociales y naturales del mundo. También los autores del Instituto de Santa Fe (Lewin, 2002; Waldrop, 1992) afirman que la mayor parte de la naturaleza es no lineal.

La no linealidad es una temática fundamental para la Teoría del Caos, que sería vista más adelante.

❖ **Causalidad compleja**

Las críticas al determinismo clásico, la introducción de las probabilidades, de los sistemas que retroactúan sobre si mismos, de la no linealidad y las interacciones, sitúan a la causalidad en una posición complicada.

Sin embargo, para los autores que tratan el tema, la complejidad no implica un abandono de la causalidad, sino que la necesidad de asumir una causalidad compleja (Buckley, 1967; Byrne, 1998; Morin, 1983; 1984; 2001; Von Bertalanffy, 1968).

La causalidad clásica era definida según 3 condiciones: la precedencia en el tiempo de causa y efecto; la existencia de una relación entre ambas variables y la no existencia de una relación espuria. A esto se le podría agregar que la causalidad presente un proceso activo (Kenny, 1979).

Von Bertalanffy (1968) afirma que la causalidad unidireccional resulta insuficiente. La noción de totalidad y holismo implican que, en última instancia, hay que pensar en términos de sistemas de elementos de interacción mutua.

La causalidad compleja, incorpora una serie de temas nuevos a esta problemática clásica. Byrne (1988) resume estos problemas en términos de dos aspectos: para empezar, los resultados se encuentran determinados no por causas simples sino múltiples y estas causas pueden interaccionar de manera no aditiva. Esto implica que causas complejas pueden fácilmente generar resultados caóticos. Por lo tanto, donde existe caos, el tema de la precisión de las mediciones resulta aún más importante.

Para Buckley (1967) las cadenas causales circulares, o retroalimentación, hacen referencia a una relación que va más allá de relaciones mutuas entre las partes. En este caso, el efecto de un hecho influye directamente sobre el propio hecho original, mediante una o varias variables de carácter intermedio.

Morin (2001; 2005) distingue entre distintos tipos de causalidades. La causalidad lineal es aquella donde una causa produce un efecto. En la causalidad circular retroactiva, el efecto puede retroactuar en la causa. Por último, en la causalidad recursiva, el producto es productor de aquello que lo produce. La causalidad generativa, implica que existe una causalidad que se genera en y por el proceso productor de sí. La causalidad circular implica que se transforma permanentemente desde estados improbables a estados locales y temporalmente probables.

Según Morin (2001), en la causalidad compleja puede ocurrir que:

- Las mismas causas pueden conducir a efectos diferentes y/o divergentes
- Causas diferentes pueden producir los mismos efectos
- Causas pequeñas pueden acarrear efectos muy grandes
- Causas grandes pueden acarrear efectos muy pequeños
- Algunas causas son seguidas de efectos contrarios
- Los efectos de las causas antagonistas son inciertos
- La causalidad compleja no es lineal, es circular e interrelacional, la causa y efecto han perdido su sustancialidad. La causa pierde su omnipotencia y el efecto su omnidependencia. Se pueden transformar el uno en el otro.

❖ **El papel del observador**

Todas las temáticas analizadas han implicado, según los autores, la necesidad de cambiar el papel del observador en lo observado. Como se planteó anteriormente, para la ciencia clásica, la observación era entendida como totalmente objetiva, lo que requería asumir que el sujeto que estudiaba se encontraba totalmente separado del objeto estudiado (Morin, 2001).

Sin embargo, existe acuerdo entre los distintos autores de la complejidad (Capra, 2003a; Martínez, 1997; Maturana y Varela, 1990; Morin, 1988; 2001; 2005; Prigogine; 2004) en que el observador no puede ser eliminado de la ecuación.

Valéry (en Prigogine, 2004) afirma que el determinismo es solamente concebible para un observador que se ubica fuera del mundo. Sin embargo, nosotros

describimos el mundo desde dentro. Según Capra (2003a) no es la naturaleza en sí misma lo que estudiamos, sino que la naturaleza expuesta a nuestros métodos de observación. Para Martínez (1997), no es posible dividir el proceso de observación de lo observado. Dado que el observador construye el instrumento de medida, es obvio que la naturaleza observada no es en sí misma, sino según como la exponemos a nuestro método de búsqueda. Según Heissenberg (en Martínez, 1997), la observación juega un rol decisivo en la realidad, la cual es distinta según si la observamos o no.

Maturana y Varela (1990), por su parte, afirman que no es posible dar una descripción objetiva de lo investigado, dado que el fenómeno que se estudia involucra al propio investigador. Los autores llaman a esta situación una tautología cognoscitiva, lo que quiere decir que no es posible explicar el universo de conocimientos, experiencias, de percepciones del ser humano desde una perspectiva independiente del mismo universo. Por lo tanto, el conocimiento humano solamente puede ser conocido desde sí mismo. A esto, los autores le suman el hecho de que ninguna explicación puede ser universal, porque los significados usados en el lenguaje son siempre generados por una cultura particular. Por lo tanto, no es posible demostrar la existencia de una naturaleza de manera independiente de la experiencia perceptual que es el acto de observación. De igual manera, Morin (1988) afirma que ningún sistema cognitivo puede conocerse exhaustivamente a partir de sus propios instrumentos.

El problema del conocimiento del conocimiento, es que implica la problemática de la reflexividad y, por lo tanto, no debe excluir al que conoce (Morin, 1988). Es más, Morin (2001; 2005) afirma que las observaciones no pueden ser separadas de su observador, por lo que este debe ser incorporado en su observación. Por lo tanto, el conocimiento debe convertirse en su propio objeto de investigación, reconocerse y problematizarse (Martínez, 1997; Morin, 1988). Morin (1988) concluye que no hay conocimiento sin el conocimiento del conocimiento. Por lo tanto, propone un conocimiento que intente conocer a sí mismo, esto es, una ciencia con consciencia (Morin, 1984).

❖ **Hacia una ciencia unitaria**

Los distintos teóricos de la complejidad plantean la necesidad de la creación de un paradigma unitario de la ciencia. Según Capra (2003a) el paralelismo en distintos campos se debe a que muchos principios generales son aplicables a los sistemas, con independencia de su naturaleza. Por ejemplo, las comunidades ecológicas y humanas son sistemas vivos que muestran los mismos principios de organización. Son redes organizativamente cerradas, que intercambian flujos de energía y recursos con el medio (Capra, 2003a; 2003b).

Nicolis y Prigogine (Nicolis y Prigogine, 1997; Prigogine, 1997b) afirman que varios cambios en la física han llevado a asumir que ya no es posible distinguir entre ciencias naturales y humanas. Por ejemplo, la física clásica aspiraba a estudiar lo inmutable, sin problematizar el tiempo. Sin embargo, desde la aparición de las ciencias de la evolución, las ciencias naturales volvieron a cuestionarse la paradoja del tiempo. A su vez, se asumía que en la física el observador se encontraba fuera del sistema, mientras que en las ciencias sociales se encontraba dentro del mismo. Hoy es difícil realizar estas distinciones.

Morin (1983), por su parte, afirma que es necesario comenzar una nueva ciencia ecológica que no parcialice ni especialice las disciplinas. Esta ciencia hace comunicar necesariamente naturaleza y cultura.

Por lo tanto, Situngkir (2003) afirma que los esfuerzos actuales se encuentran en la unificación de las ciencias. También Morin (2001) concluye que es necesario articular las esferas antropológicas, biológicas y físicas. De hecho, afirma que el nuevo paradigma debe ser capaz de incluir el estudio del hombre, pero sin reducirlo. Por lo tanto, el paradigma de la complejidad debe resultar conveniente al conocimiento del hombre (Morin, 2005).

Un ejemplo muy claro de los intentos por crear una ciencia unitaria es el caso del Instituto de Santa Fe (que será presentado en mayor profundidad más adelante). Este instituto está constituido por investigadores de muchas disciplinas distintas. Parten del supuesto que la ciencia que estudia la naturaleza y al hombre es la misma (Lewin, 2002; Waldrop, 1992).

2.5 Las Especificidades de la Complejidad

a. El Pensamiento Complejo

Morin es uno de los teóricos más relevantes de la complejidad. Como se ha visto anteriormente, ha teorizado sobre casi todos los ámbitos que resultan relevantes para las teorías de la complejidad.

Lo particular de Morin, es que para él, la complejidad es una manera de pensar, que implica importantes cambios de la manera de pensar de la ciencia clásica. Para Morin (1983, p. 24) el modo de pensamiento debe *“respetar la multidimensionalidad, la riqueza, el misterio de lo real y que sepa que las determinaciones cerebral, cultural, social, histórica que experimenta todo pensamiento codeterminan siempre el objeto de conocimiento. Es a esto a lo que llamo pensamiento complejo”*. De esta manera, el autor le otorga especial importancia a la manera de pensar en complejidad.

De esta manera, afirma que la complejidad es aquella donde se establece una comunicación entre objeto y entorno, observador y observado. Es aquella donde no se sacrifica el todo a la parte o la parte al todo, sino que se concibe la problemática de la organización. El pensamiento complejo es un diálogo entre orden, desorden y organización (Morin, 1983).

Morin (1983; Villanueva, 2006) propone tres principios para pensar la complejidad:

- 1. Principio dialógico.** Este principio afirma la necesidad de mantener la dualidad en el seno de la unidad. Por ejemplo, en el caso del orden y el desorden, es necesario asumir que, si bien son enemigos, en ciertos casos colaboran y producen organización y complejidad.
- 2. Principio de la recursividad organizacional.** Este principio rompe con la linealidad de causa/efecto, de producto/productor, asumiendo que todo lo que es producido, es a su vez, productor. De esta manera, por ejemplo, somos productores de un proceso de reproducción, anterior a nosotros mismos. A su

vez, cuando somos producidos, nos volvemos productores del proceso que va a continuar.

- 3. Principio hologramático.** Este principio tiene que ver con el hecho de que no solamente la parte está en el todo, sino que también el todo está en la parte.

b. Los Sistemas Disipativos

Prigogine es considerado el fundador de la termodinámica no lineal, abordando los sistemas lejos del equilibrio y las fluctuaciones que pueden hacer que un sistema tenga un comportamiento diferente del hasta entonces descrito (Briggs y Peat, 1989).

Prigogine (1997; 2004) distingue entre dos tipos de sistemas dinámicos: los sistemas próximos y los lejanos al equilibrio. En el caso de los sistemas cercanos al equilibrio, si el sistema es perturbado, este responde reestableciendo su condición inicial. Por esta razón, estos sistemas son denominados como estables. Por otro lado, en el caso de los sistemas alejados del equilibrio, y como caso extremo, los sistemas caóticos, las perturbaciones hacen que el sistema entre en un estado inestable. El punto donde ocurre esto es el punto de bifurcación. Al volverse inestable la solución primitiva, se producen nuevas soluciones. La aparición de bifurcaciones en estados alejados del equilibrio introducen un elemento azaroso.

La conclusión de esto es que el mundo de los sistemas dinámicos estables es un mundo estático y predecible, y, por lo tanto, determinista. Sin embargo, tratar al mundo como estable es una aproximación, y por lo tanto, una idealización (Prigogine, 1997a; 1997b). En cambio, según Prigogine, nuestro mundo tiene poco de estable. De hecho, predominan en él fluctuaciones, bifurcaciones e inestabilidades en todos los niveles (Prigogine, 1997b; Prigogine y Stengers, 1990).

Lo primordial de la diferencia entre ambos tipos de sistemas es que, como lo demostró Poincaré a fines del siglo XIX, los problemas son fundamentalmente diferentes dependiendo de si se trata de un sistema dinámico estable o no (Prigogine, 1997a). De hecho, de acuerdo a Prigogine (1997a; 1997b; 2004;

Prigogine y Stengers, 1990), en el equilibrio y cerca del equilibrio las leyes de la naturaleza son universales, sin embargo, lejos del mismo, se tornan específicas y dependen de procesos irreversibles. A su vez, los sistemas que se encuentran lejos del equilibrio deben de ser descritos por ecuaciones no lineales (Capra, 2003a).

Por otra parte, solamente en estados lejos del equilibrio es posible asociar procesos irreversibles a la formación de orden. Esto sucede dado que en condiciones de equilibrio las moléculas son independientes, mientras que en condiciones de no equilibrio, aparecen correlaciones de largo alcance. Sin estas correlaciones no habría vida. Por lo tanto, solo es posible hablar de sistemas en situaciones de no equilibrio. Esto permite concluir que los fenómenos irreversibles no llevan solamente a un aumento del desorden, sino que tienen a su vez un papel constructivo importante (Prigogine, 1997a; 1997b; 2004; Prigogine y Stengers, 1990).

Otro tema fundamental son las bifurcaciones. Cuando un sistema se encuentra cerca del equilibrio, las fluctuaciones no generan grandes efectos. Sin embargo, lejos del equilibrio, adoptan un papel central. Por medio de las fluctuaciones se producen puntos de bifurcación. En estos puntos, el sistema elige uno de los posibles regímenes de funcionamiento, introduciendo, de esta manera, un elemento probabilístico irreductible (Capra, 2003a; 2003b; Prigogine, 1997a; 1997b; 2004; Nicolis y Prigogine, 1997). Esto lleva a la imposibilidad de hablar de lo cierto, y a la necesidad de hablar de lo posible, dado que un sistema puede adoptar cualquiera de los estados posibles (Prigogine, 1997b; Prigogine y Stengers, 1990). A su vez, las bifurcaciones introducen un carácter histórico a la evolución de los sistemas. Las bifurcaciones tienen la característica de ser una mezcla de determinismo y probabilidades, dado que el punto de bifurcación es probabilística, mientras que entre los distintos puntos es posible hablar de leyes deterministas (Capra, 2003a; Prigogine; 1997b; 2004). Prigogine (2004) habla de orden por fluctuación, cuando por encima de un punto crítico, ciertas fluctuaciones se amplifican dando origen a una corriente macroscópica a un nuevo orden, que se estabiliza por intercambios de energía con el medio. Las bifurcaciones son, por lo tanto, una fuente de innovación y diversificación, dado que permiten que el sistema adopte nuevas soluciones. Capra (2003b) se refiere a este proceso como la emergencia de orden espontáneo en puntos críticos de inestabilidad.

Al analizar las situaciones alejadas del equilibrio, en las cuales existe un importante ingreso de energía desde el exterior, Prigogine fue descubriendo la aparición de orden desde el caos. De esta manera, observó que en los sistemas alejados del equilibrio no sólo se desintegran sistemas, sino que también emergen nuevos (Briggs y Peat, 1989).

Estas estructuras, las cuál son tal vez la teorización más importante de Prigogine, son las estructuras disipativas. Las estructuras disipativas son sistemas abiertos que utilizan la disipación como una fuente de orden (Capra, 2003a; Martínez, 1997). De esta manera, estas estructuras requieren para mantenerse flujo de energía del mundo externo. De hecho, no pueden existir alejadas del mundo externo y desaparecen si no cuentan con aportes permanentes de energía y materia. Por otro lado, las estructuras disipativas son capaces de reaccionar en respuesta a las condiciones del medio y de crear sus propios límites. Las estructuras disipativas se forman cuando el medio externo se mantiene en un estado de inestabilidad, posibilitando la amplificación de las fluctuaciones y llevando a estados macroscópicos más organizados (Prigogine, 2004). De hecho, Capra (2003a) afirma que un organismo en equilibrio en realidad está muerto. Los organismos vivos se encuentran en un estado alejado del equilibrio, si bien se mantienen estables a lo largo del tiempo. De esta manera, las estructuras disipativas se generan y se mantienen en condiciones inestables, gracias a los intercambios de energía con el medio (Prigogine, 2004). Por lo tanto, mantienen estable su estructura, si bien existe un incesante flujo y cambio de componentes (Capra, 2003a; 2003b). Las estructuras disipativas no pueden ser entendidas en un mundo de leyes reversibles. De hecho, en general aumentan la producción de entropía (Prigogine, 1997a; 1997b). Por esta razón, Capra (2003a) afirma que las estructuras disipativas son islas de orden en un mar de desorden. Para mantener su orden, aumentan el desorden en el entorno. Por lo tanto, existe orden en medio del desorden, mientras que el sistema como un todo sigue aumentando su entropía.

Las estructuras disipativas se caracterizan por la ruptura de simetría, por una gran variedad de posibilidades de elección y por correlaciones de carácter macroscópico (Nicolis y Prigogine, 1997). Para Harvey y Reed (en Byrne, 1998), los sistemas disipativos son la expresión más general del caos determinista. Según

Nicolis y Prigogine (1997), las estructuras disipativas son el nacimiento de la complejidad.

c. Los Sistemas Complejos Adaptativos

El Instituto de Santa Fe (ISF, de ahora en adelante) surgió desde conversaciones informales entre un grupo de amigos en el Laboratorio Nacional de Los Álamos, en el año 1983. El instituto se formó bajo el principio de no excluir ninguna disciplina, dado que de hecho, no existirían diferencias entre la ciencia que estudia la naturaleza y la que estudia al hombre (Lewin, 2002; Waldrop, 1992). En consecuencia, el ISF se formó con un grupo ecléctico de científicos de varias áreas, incluyendo desde recién graduados, hasta premios Nobel, como Murray Gell-Mann y Philip Anderson.

Tal vez lo más relevante de este grupo de estudio, es que se definen como los creadores de una nueva ciencia: la ciencia de la complejidad (Waldrop, 1992). De hecho, los autores se refieren a la revolución de la complejidad. Según Arthur (en Waldrop, 1992), esta revolución comenzó cuando alguien vio la posibilidad que desde un sistema muy simple se diera lugar a consecuencias inmensamente complicadas e impredecibles.

La principal pregunta que busca responder el ISF es porqué si según la segunda ley de la termodinámica, existe una tendencia inexorable hacia el desorden, la disolución y el decaimiento, sin embargo, se generan estructuras en todas las escalas de la vida (Waldrop, 1992). Por lo tanto, para el ISF, la ciencia de la complejidad trata de la estructura y del orden (Lewin, 2002). De hecho, estos autores se refieren a la existencia de un orden espontáneo, a una autoorganización, como propiedad natural de los sistemas complejos (Lewin, 2002; Waldrop, 1992). Es el supuesto de esta autoorganización la que guía todas las investigaciones del ISF.

De esta manera, el ISF se distingue de la ciencia clásica, dado que su análisis no gira en torno a los equilibrios simples, sino que en torno a sistemas dinámicos, no predecibles con facilidad y muy creativos. Parten del supuesto de que los sistemas dinámicos no lineales, que en la superficie parecen sumamente complejos, pueden

estar definidos por una serie de procesos simples (Lewin, 2002). De hecho, Murray Gell-Mann se refiere a esto como la "*complejidad superficial que surge de una simplicidad profunda*" (Lewin, 2002, p.27).

Un concepto relevante del ISF es el de la transición de fases, concepto adoptado desde la física. Un cambio de fase es un punto en el que se llega al límite y se cruza. Stuart Kaufmann utilizó este concepto para definir la existencia del límite del caos. El límite del caos es un estado intermedio entre un sistema congelado y uno caótico, el cual demuestra ser muy estable y eficaz. Según Kaufmann, la adaptación de los sistemas los lleva a posicionarse en este límite del caos (Lewin, 2002). Waldrop (1992) define el eje del caos como el punto donde la vida tiene suficiente estabilidad para mantenerse y suficiente creatividad para merecer el nombre de vida. En esta fase, un sistema complejo puede ser espontáneo, adaptativo y vivo.

El análisis de las distintas fases, permite determinar lo que ocurre con las perturbaciones a los sistemas. En estados congelados, con baja conectividad entre las partes del sistema, los efectos de una perturbación inicial se terminan agotando rápidamente, permitiendo mantener una gran estabilidad. En cambio, en un estado caótico, con una alta conectividad, cualquier cambio puede propagarse con fuerza por todo el sistema y, por lo tanto, genera sistemas muy inestables. Sin embargo, en el estado intermedio, el límite del caos, con interacciones internas cuidadosamente adaptadas, algunas perturbaciones pueden producir pequeños cambios, y otras avalanchas completas (Waldrop, 1992; Capra, 2002).

Probablemente el concepto más relevante producido por el ISF es el de los sistemas complejos adaptativos. Según Gell-Mann (en Lewin, 2002), estos sistemas interaccionan con el entorno aprendiendo de la experiencia, y pudiéndose adaptar como resultado. Waldrop (1992) afirma que los sistemas adaptativos buscan activamente modificar las cosas para su propia ventaja. Según Holland (en Waldrop, 1992), quien aplica este análisis a la economía, es posible distinguir las siguientes características de los sistemas complejos adaptativos:

- Cada sistema es una red de varios agentes que actúan en paralelo. Esto implica que el control de los sistemas complejos adaptativos es muy disperso,

- no existiendo un centro para el mismo. Por lo tanto, la competencia y cooperación entre los agentes es fundamental.
- Un sistema complejo adaptativo tiene varios niveles de organización, con agentes en cada nivel, que sirven de ladrillos para los agentes del nivel siguiente. Estos ladrillos son constantemente revisados y arreglados según la experiencia del sistema.
 - Todos los sistemas complejos adaptativos anticipan el futuro, es decir, hacen predicciones basadas en modelos internos del mundo.
 - Los sistemas complejos adaptativos tienen varios nichos, cada uno de los cuales puede ser explotado por un agente para llenar ese nicho. El solo acto de llenar un nicho abre nuevos nichos. De esta manera, el sistema va creando cada vez nuevas oportunidades

El concepto de autoorganización tiende a criticar la posibilidad de una evolución basada solamente en la selección natural darwinista. Para los autores, la evolución por selección resulta imposible si se toma en cuenta el tiempo que necesitaría para llegar a crear estructuras tan simples como una molécula. Ni hablar de crear humanos. En el ISF se le atribuye una importancia fundamental a la autoorganización en el proceso evolutivo. La selección puede actuar solamente dado que los sistemas complejos adaptativos generan orden espontáneo (Lewin, 2002; Waldrop, 1992). Según Waldrop (2002), la vida no puede ser un accidente azaroso, sino es más bien la compulsión incesante de la naturaleza por la autoorganización.

Otra propiedad fundamental de los sistemas complejos adaptativos es que la complejidad va aumentando a lo largo de la evolución, alcanzando por sí mismo el límite del caos (Lewin, 2002; Waldrop, 1992). Sin embargo, los autores se preguntan porqué esto es así. Según Kaufmann (en Waldrop, 1992), el aumento de la complejidad tiene algo que ver con sistemas lejos del equilibrio, que se encuentran construyéndose a si mismos, aumentando los niveles de organización.

d. La Autopoiesis

Humberto Maturana y Francisco Varela trabajan desde la biología. Los autores estudian los sistemas vivos en términos de su organización, interesándose por los procesos y relaciones entre procesos, realizados por medio de los componentes de

los sistemas. Sostienen que los sistemas vivos son máquinas, asumiendo un criterio no animista. El sistema vivo es definido por su organización y, por lo tanto, es posible explicarlo como se explica cualquier organización, esto es, en términos de relaciones. A su vez, asumen que la organización es común a todos los sistemas vivos, sin importar la naturaleza de sus componentes (Capra, 2003a; Maturana y Varela, 1994).

El concepto fundamental de Maturana y Varela es el de la autopoiesis. "Auto" se refiere a "sí mismo"; mientras que "poiesis" significa "creación". Por lo tanto, la autopoiesis es la creación de sí mismo (Capra, 2003a). Los autores (2004, p.69) definen una máquina autopoietica como *"una máquina organizada como un sistema de procesos de producción de componentes concatenados de tal manera que producen componentes que: i) generan los procesos (relaciones) de producción que los producen a través de sus continuas interacciones y transformaciones, y ii) constituyen a la máquina como una unidad en el espacio físico"*. De esta manera, una máquina autopoietica produce su propia organización a través de la producción de sus propios componentes. Esta producción se realiza en un contexto de continua perturbación y compensación de esas perturbaciones. En consecuencia, la máquina autopoietica es un sistema homeostático, que tiene como variable constante su propia organización. Para que una máquina siga siendo autopoietica, es necesario que las relaciones de producción que la definen sean continuamente regeneradas por los componentes que producen (Maturana y Varela, 2004). De esta manera, Rodríguez y Arnold (1999) afirman que los sistemas autopoieticos no solamente son autoorganizadores, sino que también se producen a sí mismos y lo hacen porque tienen la capacidad de generar sus propios elementos por medio de los elementos que lo componen.

Las máquinas autopoieticas tienen las siguientes características (Maturana y Varela, 2004):

- **Son autónomas.** Esto quiere decir que sus cambios se encuentran subordinados a la conservación de su propia organización. Además, tiene que ver con el hecho de que todos los aspectos del operar de su vivir tienen que ver sólo con él.

- **Poseen individualidad.** Conservan una identidad, por medio de la mantención de su organización, de manera invariante. La identidad es constituida de manera circular, esto es, la red de producciones produce la existencia del sistema mismo. De hecho, la autopoiesis es la subordinación de todo cambio en el sistema a la mantención de su organización y a la conservación de su unidad.
- **Son definidas como unidades por y sólo por su organización autopoietica.** Por lo tanto, sus operaciones definen los límites en el proceso de autopoiesis.
- **No tienen entradas ni salidas.** Si bien pueden ser perturbadas por hechos externos y experimentar cambios internos para compensar estas perturbaciones, estos se encuentran siempre subordinados a la conservación de la organización del sistema. De hecho, los cambios que experimenta un sistema autopoietico ocurren sin que este pierda su identidad. Por lo tanto, están siempre en correspondencia con las perturbaciones que sufre sin perder su identidad. El mantenimiento de su identidad y, por lo tanto, de su organización, es lo que los autores denominan clausura operacional.

Los componentes de una unidad autopoietica se encuentran relacionados en una red de interacciones continuas. Un sistema autopoietico se diferencia de su medio a través de su propia dinámica. En consecuencia, no hay separación entre productor y producto. El hacer y el ser de un sistema autopoietico son inseparables (Maturana y Varela, 2004).

El término acoplamiento estructural se refiere a la necesidad de una unidad compuesta de existir en su dominio de existencia en una relación de complementariedad con éste. De esta manera, el sistema y su medio se gatillan mutuamente cambios de estado, sufriendo perturbaciones, pero no destrucciones (Rodríguez y Arnold, 1999). De esta manera, el acoplamiento surge como resultado de modificaciones mutuas (Maturana y Varela, 1984; 2004).

Los sistemas autopoieticos son cerrados en su organización y abiertos en la importación de energía. También son cerrados con respecto a la información. En este sentido, la teoría de Maturana y Varela, se contradice con la teoría de los sistemas cerrados (Rodríguez y Arnold, 1999).

Tal vez lo más fundamental de los sistemas autopoieticos es que si bien ocurren cambios estructurales, la organización se mantiene invariante (Maturana y Varela, 1984; Rodríguez y Arnold, 1999). Estos cambios estructurales se viven según la interacción con el medio, llegando a formar un itinerario de acoplamiento estructural (Capra, 2003b).

Maturana y Varela (1984; 2004) afirman que los sistemas vivos son redes de interacciones moleculares que se producen a sí mismos y que definen sus propios límites. En consecuencia, se caracterizan por producirse continuamente a sí mismos. Por esta razón, tienen una organización autopoietica. Es más, los autores plantean que si un sistema es autopoietico, es viviente. Esto los lleva a concluir que "la noción de autopoiesis es necesaria y suficiente para caracterizar la organización de los sistemas vivos" (Maturana y Varela, 2004).

Sin embargo, los autores no opinan lo mismo con el caso de la sociedad. No están de acuerdo con Luhmann, quien afirma que lo que se reproduce son las comunicaciones, dejando fuera del sistema a los seres vivos (Maturana y Varela, 2004).

Otra teorización relevante de Maturana y Varela tiene que ver con la cognición. Según los autores, los sistemas vivos son sistemas cognitivos. De hecho, el proceso de vivir es un proceso de cognición. A su vez, la autopoiesis se encuentra fuertemente vinculada a la cognición. Ambos son aspectos del mismo proceso de vida. Todos los sistemas vivos son cognitivos, mientras que la existencia de una red autopoietica es un requisito para la cognición. Un organismo vivo se relaciona con su entorno por medio de interacciones cognitivas (Capra, 2003a). Según Bateson (en Capra, 2003), el proceso de cognición es el proceso mismo de vivir. La cognición para Maturana y Varela (en Capra, 2003b) implica la autogénesis y la autoperpetuación de redes vivas. La cognición organiza los sistemas vivos en todos los niveles de la vida.

e. Teoría del Caos

Bajo el nombre de Teoría del Caos es posible encontrar una serie de investigaciones interdisciplinarias, que abarcan una multitud de temas distintos. Entre estos podemos encontrar los campos de la dinámica no lineal, la termodinámica irreversible, la meteorología y la epidemiología. Según Hayles (1990, p.29), la Teoría del Caos es *"el estudio de los sistemas complejos, en el que los problemas no lineales que desconcertaban a los contemporáneos de Poincaré son considerados por derecho propio, y no como molestas desviaciones de la linealidad"*. De igual manera, se plantea que el cambio paradigmático ocurrido implica asumir que lo no predecible es un hecho de la vida, y no una aberración.

Varios autores (Briggs y Peat, 1989; Hayles, 1990; Zúñiga, 2003) afirman que el creador de la Teoría del Caos fue Henri Poincaré, quién puso en cuestión el modelo newtoniano de explicación del mundo. Según Poincaré, las ecuaciones newtonianas funcionan a la perfección cuando se trabajaba solamente con dos cuerpos, como por ejemplo, la tierra y el sol. Sin embargo, al momento de incluir la luna, la atracción ejercida por esta en la tierra implicaba la generación de perturbaciones en la órbita terrestre, modificando la distancia entre la tierra y el sol, entre otros. A este problema se le conoció como el problema de los tres cuerpos. Poincaré no sólo criticó las ecuaciones newtonianas, sino que planteó la necesidad de una nueva matemática y una nueva ciencia para explicar la dinámica de sistemas complejos.

El principio más conocido con respecto a la Teoría del Caos es el efecto mariposa. El fundador de este principio es Edgard Lorenz, quien intentaba construir un modelo de las condiciones meteorológicas de la Tierra, por medio de tres ecuaciones diferenciales no lineales. Al usar estas ecuaciones, obtuvo una gran impredecibilidad. Luego de analizar el tema se dio cuenta de que, dado que usaba ecuaciones no lineales, las insignificantes diferencias en las condiciones iniciales se habían amplificado, hasta el punto de generar diferencias significativas (Briggs y Peat, 1989; Byrne, 1998; Capra, 2003; Hayles, 1990; Mier, 2002;). En términos del pronóstico del tiempo, este resultado implica que si una mariposa mueve sus alas en Honk Kong, puede desatar una tormenta en Nueva York. En su modelo meteorológico, Lorenz encontró la presencia de un atractor extraño, el cual será analizado a continuación (Hayles, 1990). Una característica importante de estos

sistemas, según el mismo Lorenz (en Briggs y Peat, 1989) es que ninguna cantidad de detalles adicionales puede aumentar la predicción.

A continuación se presentan las principales temáticas de la Teoría del Caos:

❖ **Orden y caos**

La principal característica de la teoría del caos es la incorporación del caos y el desorden al estudio de la realidad. Según Briggs y Peat (1989), la turbulencia, la irregularidad y la imprevisibilidad se encuentran por doquier y, sin embargo, siempre han sido asumidos como ruido y como contingencias aleatorias exteriores. De esta manera, se pensaba que detrás del caos se encontraban cimientos ordenados, que aún no habían sido descubiertos. Hoy, se está descubriendo que esto es un error. De hecho, para Balandier (1988), la física debe reconocer la complejidad, esto es, un mundo donde las nociones de orden y de equilibrio se vinculan con la de desorden.

Con respecto al papel del desorden, distintos autores afirman que orden y desorden se encuentran vinculados (Balandier, 1988; Hayles, 1990). De hecho, según Hayles (1990, p.134), el caos es aquello que hace posible el orden. La vida surgiría gracias a los procesos disipativos que producen entropía. De esta manera, afirma que *"El caos es el vientre de la vida, no su tumba"*. A su vez, Balandier (1988) postula que el acrecentamiento del desorden permite la formación de un nuevo orden, y de esta manera, de un aumento de la complejidad.

❖ **No linealidad**

El manejo de ecuaciones no lineales exige el uso de técnicas matemáticas que no eran conocidas hasta hace algún tiempo. Por esta razón, se realizaban aproximaciones lineales y nunca se hacían análisis fuera de esta linealidad. Según Briggs y Peat (1989), por medio de esto fue posible preservar el viejo hechizo reduccionista. El problema es que en general, muchos sistemas funcionan de manera no lineal, especialmente en las ciencias sociales (Zúñiga, 2003). Recién en

los años 70, con los avances matemáticos y la aparición de los computadores, fue posible meterse en el mundo de las ecuaciones no lineales, abriendo los ojos ante un mundo totalmente nuevo.

En una ecuación lineal, las magnitudes entre causa y efecto en general se corresponden. De esta manera, pequeñas causas dan lugar a pequeños efectos. En cambio, en las ecuaciones no lineales, esta correspondencia no es necesaria. Esto último implica que exista una incongruencia entre causa y efecto, pudiendo, por ejemplo, una pequeña causa, dar origen a un efecto grande. (Briggs y Peat, 1989; Hayles, 1990). Debido a esto, según Briggs y Peat (1989), la no linealidad imposibilita la predicción exacta.

❖ **Sensibilidad a las condiciones iniciales**

Muy ligado a lo anterior, cuando un sistema es muy sensible a cualquier fluctuación, se observa una sensibilidad a las condiciones iniciales. Por lo tanto, a menos que fuera posible especificar las condiciones iniciales con una precisión infinita, los sistemas caóticos rápidamente se convierten en impredecibles (Briggs y Peat, 1989; Capra, 2003; Hayles, 1990).

❖ **Iteraciones**

La iteración implica que el resultado de un cálculo se utiliza como comienzo del siguiente. Cuando se iteran funciones fuertemente no lineales se producen caminos que tienen pliegues en su interior cuando se despliega en espacio de fases. Esto aumenta la imprecisión del conocimiento, dado que desde diferencias iniciales muy pequeñas, se amplifica hasta degradarse todo conocimiento (Hayles, 1990).

❖ **Bifurcaciones**

Como otra causa de la no linealidad, se observa que pequeñas fluctuaciones no solo no se atenúan a medida que va prosiguiendo la repetición, sino que se

magnifican a través de bifurcaciones (Hayles, 1990). Esto quiere decir que en ciertos puntos críticos, un pequeño cambio puede producir un impacto desproporcionadamente grande, llevando a que la ecuación que describe el sistema toma una nueva conducta (Briggs y Peat, 1989).

❖ **Atractores extraños**

Un atractor es un punto que atrae hacia sí un sistema. Capra (2003a) afirma que existen tres modelos básicos de atractores: atractores puntuales, que llevan a un equilibrio estable; atractores periódicos, que llevan a oscilaciones periódicas y atractores extraños, que corresponde a sistemas caóticos. En el caso de los atractores extraños, el conocimiento del punto de partida de una secuencia no ayuda a saber dónde se encontraría el sistema en cualquier momento futuro, pudiendo llevar a que puntos muy cercanos inicialmente, terminaran muy apartados. En los atractores extraños, el sistema nunca se repite, cubriendo en cada ciclo una nueva región del espacio fase. Sin embargo, a pesar de que este movimiento parece errático, los puntos no se distribuyen aleatoriamente, sino según un patrón complejo, altamente organizado. Los atractores extraños presentan una extraña combinación entre azar y orden, entre simplicidad y complejidad, entre determinismo e impredecibilidad (Briggs y Pear, 1989; Hayles, 1990).

❖ **Fractales**

En la física clásica se asumía que los objetos eran independientes de la escala utilizada para medirlos. En la Teoría del Caos, en cambio, se pone especial énfasis en la escala. En el caso de formas irregulares complejas, el supuesto de que los objetos son independientes a la escala no funciona. En estos casos, si se realizan mediciones en escalas de diferentes longitudes, estas no convergen hacia un límite, sino que van aumentando a medida que las escalas de medición decrecen. De esta manera, cualquier figura que tiene detalles en escalas cada vez más pequeñas, tiene finalmente una longitud infinita. Según esta lógica, es posible decir que la línea costera de Gran Bretaña y la de Manhattan son igualmente largas: ambas son infinitas (Mandelbrot, en Briggs y Peat, 1989; Capra, 2003; Mier, 2002). Mandelbrot

resolvió este problema por medio de la geometría fractal, la cual logra expresar esta complejidad aumentando las dimensiones (Briggs y Peat, 1989; Hayles, 1990). Con la geometría fractal, ha sido posible crear modelos muy precisos de una gran variedad de formas naturales irregulares. De hecho, es posible concluir que una enorme complejidad puede ser generada por medio de un procedimiento iterativo muy simple (Capra, 2003a).

❖ **Autosimilitud**

Según los autores del caos, es posible observar simetrías recursivas que aparecen en diferentes niveles de un sistema. Así, existen formas complejas que tienen partes menores con la misma forma que el objeto. Un ejemplo de esto es como un tallo de un árbol reproduce la forma de una rama y una rama reproduce la forma de un árbol. El todo y las partes se encuentran relacionadas por medio de la autosimilitud (Hayles, 1990; Briggs y Peat, 1989).

2.6. Conclusiones de las Teorías de la Complejidad

Se han revisado tanto los temas analizados en común por los autores de la complejidad, así como los temas propios de cada uno. Lo primero que hay que destacar, es que existe un acuerdo generalizado en un número importante de supuestos de la complejidad, que aparecen en las teorías de la mayoría de los autores.

A continuación se presentan los supuestos compartidos que permiten afirmar que existe una base común en todas las teorías de la complejidad:

1. La realidad es entendida desde una mirada sistémica y holista. Esto implica poner atención en la relación entre los componentes del sistema y de estos con el entorno. A su vez implica una crítica a una mirada más analítica.
2. Los sistemas tienen la característica de la emergencia, lo que implica que el todo es más que la suma de las partes y que no puede, por lo tanto, ser entendido por medio del análisis de las últimas.

3. Los sistemas abiertos tienen la capacidad de retroalimentarse y regularse a sí mismos. De esta manera, son capaces de mantenerse y adaptarse al medio.
4. Existe una tendencia de los sistemas hacia el estado más probable y este es el de máxima entropía. Sin embargo, los sistemas abiertos logran, por medio de la eliminación de entropía hacia el medio, disminuir el desorden interno, constituyendo islas de organización en un mar de desorden.
5. El desorden, las inestabilidades y el azar deben ser incluidos en la comprensión de la realidad. A su vez, estos son entendidos en términos de sus capacidades de generar orden y estructuras. Sin desorden no podría existir vida.
6. La organización es un tema fundamental para los sistemas. El orden se crea por medio de la organización desde el desorden. A su vez, implica poner el énfasis en la manera en que los componentes de un sistema se interrelacionan y organizan para constituir el todo.
7. Los sistemas vivos tienen la capacidad de autoorganizarse. De hecho, es por medio de esta autoorganización que pueden mantenerse vivos.
8. Las interacciones juegan un papel esencial en la constitución de organización, ya que permiten que los elementos se encuentren y correlacionen.
9. La realidad –especialmente la realidad social– es en su mayoría no lineal. Por lo tanto, no es posible reducir todos los fenómenos a un análisis lineal.
10. La causalidad debe ser asumida como compleja. La causalidad compleja implica que puede existir equifinalidad o multifinalidad, que no existe una relación lineal entre causa y efecto, que pueden aparecer efectos contrarios, que la causalidad es circular e interrelacional, entre otros.
11. El observador es parte de la realidad que estudia, por lo que debe ser incluido en la ecuación.
12. Existe un paralelismo entre los distintos ámbitos de estudio. Por lo tanto, se rechaza una actitud analítica de separar las distintas ramas del conocimiento y se apela por la interdisciplinariedad y la unificación de las ciencias.

Los supuestos nombrados son compartidos de manera implícita o explícita por los autores de la complejidad. Por lo tanto, es posible afirmar que existe una base común que podría constituir un paradigma.

Las teorías específicas de los distintos autores son distintos intentos por utilizar estos supuestos para armar una teoría explicativa global. En todos los casos, los autores buscan explicar como es posible, que dadas las tendencias hacia el desorden máximo, se generen estructuras y, como consecuencia, vida.

Las estructuras disipativas, los sistemas complejos adaptativos, la autopoiesis, la ecología profunda, el pensamiento complejo, la teoría del caos, son todos constructos que parten de los mismos supuestos. Sin embargo, presentan diferencias en sus planteamientos, que implican que el énfasis esté puesto en temas distintos y que, por lo tanto, no puedan constituir una teoría global. Tal vez el mayor impedimento a esto último, es el hecho de que los distintos autores provienen de ciencias tan disímiles como la química, la biología y la sociología. De esta manera, los mismos supuestos son aplicados a distintos ámbitos, llegando a propuestas también distintas.

Si se aplican los componentes de un paradigma definidos por Kuhn (un aspecto cognitivo –teórico y metodológico-, una vertiente social y un conjunto de realizaciones científicas) a las teorías de la complejidad, parece difícil afirmar que estas realmente se constituyen en uno. En términos teóricos, existe una base común para todos los teóricos, sin embargo los planteamientos que nacen desde ahí son variados, y no existe una unidad de pensamiento. En términos metodológicos, es difícil afirmar que exista un método de la complejidad. Morin propone el pensamiento complejo, sin embargo, no es posible afirmar que exista realmente una técnica de la complejidad, ni una manera de hacer investigación sobre ella. En términos sociales, no existe una comunidad científica que se dedique al tema y que se encuentre de acuerdo en los planteamientos principales, más bien existen varias comunidades. Por último, aún no es posible afirmar que exista una acumulación de realizaciones científicas desde las cuales se siga trabajando. Existen algunos descubrimientos que son muy relevantes (como la irreversibilidad del tiempo o el orden espontáneo) y que son asumidos por todos los autores como un supuesto, sin embargo no existe una gran acumulación de conocimiento. Es posible afirmar que esto último ocurre principalmente porque la complejidad se ha ido consolidando en los aspectos teóricos, con un importante vacío en los métodos, tema que se verá a continuación.

Las características de las teorías de la complejidad se asemejan más bien a una época preparadigmática, en la que existen varias alternativas que disputen la explicación de la realidad. En este caso, son varias las escuelas de pensamiento que analizan la complejidad (ISF, Morin y el instituto de la complejidad, Prigogine y sus seguidores, entre otros) que si bien tienen mucho en común, no logran ponerse de acuerdo en una teoría unificada. Además, hay que recordar que aún existen importantes seguidores del paradigma anterior, que implican una dificultad en la instauración de uno nuevo.

Por lo tanto, es posible concluir que las teorías de la complejidad tienen el potencial de convertirse en paradigma, pero que, sin embargo, aún no se encuentran en esa etapa. Tampoco es posible afirmar si efectivamente algún día irán a llegar a ese punto.

3. Los Métodos de la Complejidad

Un paradigma no se compone solamente de teorías, sino también de métodos, de formas de investigar y de acumular conocimiento. Asumiendo que cada paradigma tiene asociado un método, es posible afirmar que uno de los métodos más fundamentales de la ciencia clásica es el método experimental y, en términos de análisis de los datos, la estadística. De esta manera, se puede argumentar que la estadística clásica presenta ciertas características en su funcionamiento que se asimilan a los supuestos de la ciencia clásica.

Entre estos se pueden destacar:

- **Linealidad.** Tal vez el tema más fundamental es que la gran mayoría de la misma utiliza solamente funciones de tipo lineal. Sólo en el último tiempo se ha empezado a masificar el uso de análisis de relaciones no lineales.
- **Determinismo.** Si bien la estadística trabaja en principio con probabilidad, tiene como fin último la predicción de la variable dependiente, por medio del conocimiento del valor de una variable independiente.

- **Reduccionismo.** La estadística convencional, en su gran mayoría, ha utilizado el método analítico para separar variables y relaciones entre estas, asumiendo que el todo puede ser explicado por la suma de las distintas relaciones.
- **Causalidad simple.** La causalidad que busca determinar la estadística clásica es una causalidad simple, donde causa y efecto se corresponden de manera perfecta en términos temporales, de manera lineal, donde no existe recursividad entre ambas, y donde las interacciones no tienen un peso demasiado significativo.
- **Baja tolerancia a errores, ruido y datos perdidos.** La estadística clásica es muy sensible a problemas de errores, ruido y datos perdidos en las bases de datos. La fiabilidad de los resultados se ve muy afectada en estos casos. Por lo tanto, el trabajo con datos sociales, que presentan este tipo de problemas, se ve complicado.

Por su parte, en la complejidad se ha avanzado poco en el diseño de métodos. Morin ha planteado formas de pensar la realidad desde una mirada compleja y algunos autores han empezado a utilizar técnicas que tienen características de los planteamientos de la complejidad, sin embargo, aún no se ha instaurado un método como tal. Esto último puede ir asociado al hecho de que no exista una comunidad unitaria de científicos de la complejidad.

Según Capra (2003a) las matemáticas de la complejidad han podido ser formuladas sólo recientemente, con el acceso a nuevas herramientas, capaces de permitir el diseño de modelos de interconectividad no lineal, que son características de las redes. Estas nuevas matemáticas son matemáticas de relaciones y patrones. Por el contrario, Nicolis (en Byrne, 1998) afirma que existe una imposibilidad por parte de los métodos cuantitativos para entender el fenómeno complejo. Por lo tanto, se necesitan acercamientos cualitativos.

Byrne (1998) afirma que los intentos por desarrollar métodos de regresión para leyes sociales no han funcionado bien. Si se tienen propiedades emergentes, la lógica experimental falla. Como un intento por encontrar técnicas que permitan incluir la emergencia, Byrne propone el análisis de tablas de contingencia, cluster y

análisis de correspondencia, los cuales, según él, son métodos para analizar la complejidad. Por ejemplo, en el caso de las tablas de contingencia, permite analizar un espacio con x dimensiones según los posibles estados. De esta manera, se miran las celdas con muchos casos contra las que tienen pocos casos y se ve la evolución de esto. A su vez, permite analizar el todo.

En esta investigación se plantea que los Modelos Causales recursivos y, en mayor medida, las Redes Neuronales Artificiales, presentan características de la complejidad en su funcionamiento. De esta manera, se acercan a la posibilidad de constituir un método de la complejidad.

La distinción entre métodos de la ciencia clásica y de la complejidad, parte de un gran supuesto, el cual es, que los métodos para estudiar realidades distintas son, también, distintos. De esta forma, es posible afirmar que la estadística clásica, por sus características, se ajusta para el estudio de una realidad lineal, determinista y sin importantes interacciones. Sin embargo, puede tener problemas en ser utilizada para analizar una realidad no lineal, con muchas interacciones, con causalidad compleja, entre otros. Para esto, pueden existir técnicas más idóneas, como las RNA y los modelos causales recursivos. Lo más interesante de este planteamiento, es que implica asumir que la realidad que se estudia debe ser un factor a considerar en la decisión de qué técnica utilizar.

A continuación se presentan ambas técnicas y las características que se asemejan a la teoría de la complejidad, de manera de poder comparar y contrastar estas técnicas con la estadística clásica.

3.1 Los modelos causales recursivos

❖ Generalidades

Los modelos causales (más frecuentemente denominados Modelos de ecuaciones estructurales) son una técnica que permite la estimación de relaciones de dependencias múltiples y cruzadas y que tiene la capacidad de representar conceptos

no observados en estas relaciones e incluir el error de medida en el proceso de estimación. Las ecuaciones estructurales son una serie de ecuaciones de regresión múltiples distintas, que se encuentran interrelacionadas mediante un modelo estructural. De esta manera, a diferencia de la mayoría de las técnicas estadísticas, los modelos causales son capaces de trabajar con más de una relación al mismo tiempo. A su vez, es especialmente útil porque permite que una variable dependiente se convierta en independiente en posteriores relaciones de dependencia (Hair, Anderson, Tatham y Black, 1999).

Para Byrne (2001) las principales ventajas de los modelos causales son permitir un acercamiento más bien confirmatorio que exploratorio, el cual es útil para el análisis inferencial, así como el contraste de hipótesis, la definición explícita de los errores, la incorporación de variables latentes y la estimación de efectos directos e indirectos. Según Kline (1998), los modelos causales permiten evaluar el modelo entero, lo cual permite integrar una visión a nivel macro en el análisis, más que una visión micro. Si bien los estadísticos a nivel de dos variables específicas son de interés, lo que prima es la preocupación por generar un buen modelo a nivel global.

Asher (1983) afirma que los modelos causales se están convirtiendo en una herramienta analítica cada vez más popular en las ciencias sociales. El uso de esta técnica tendría un carácter heurístico que permite incrementar nuestro entendimiento de los fenómenos sociales y políticos. Según Hair et al (1999), los modelos causales son utilizados en casi todos los campos de estudio, desde educación, marketing, psicología, sociología, entre otros. A su vez, pueden ser utilizados para analizar datos de diseños experimentales, así como no experimentales. Esto ocurre, según los autores, porque estos modelos permiten tratar varias relaciones simultáneamente y porque tienen la capacidad para evaluar las relaciones exhaustivamente y proporcionar una transición desde un análisis exploratorio a uno confirmatorio.

Los modelos causales se encuentran fuertemente vinculados a la teoría. De esta manera, el investigador define desde la teoría las variables independientes que predicen cada variable dependiente. Las hipótesis del investigador, posteriormente, se convierten en ecuaciones estructurales para cada variable dependiente (Hair et al, 1999; Kline, 1998). Kenny (1979) afirma que los modelos causales pueden ayudar al

desarrollo, modificación y extensión de la teoría en medición y sustantiva. Además, puede darle a las ciencias sociales una base más fuerte para aplicar la teoría a la resolución de problemas. Puede ser usado para determinar y testear teoría y puede proveer una base científica para la aplicación de las ciencias sociales a problemas sociales. De hecho, el error más típico es el de especificación. Esto ocurre cuando se omiten variables relevantes, lo que sesga la evaluación de la importancia de otras variables (Hair et al, 1999). Esto puede ocurrir por una falta de conocimiento acerca de los predictores de cierta variable (Kline, 1998).

Las ecuaciones estructurales pueden ser representadas gráficamente o por medio de una serie de ecuaciones de regresión (Byrne, 2001; Hair et al, 1999). Esta representación visual de las relaciones causales puede representar relaciones predictivas y asociativas. De esta manera, se utilizan flechas para representar relaciones. Las flechas directas indican relación causal directa; una flecha curvada indica correlación y una directa con dos cabezas indica una relación recíproca entre constructos (Hair et al, 1999). Las variables observadas se dibujan con cuadrados o rectángulos, las variables latentes con círculos o elipses (Kline, 1998). En vez de hablar de variables independientes, en modelos causales se habla de variables exógenas. Las variables exógenas son las que no son explicadas por otras variables del modelo. A su vez, en vez de variables dependientes, se habla de variables endógenas, que son aquellas que son predichas por el modelo (Kline, 1998). A pesar de esto, un constructo endógeno puede predecir, a su vez, otra variable. Un requisito de los diagramas de secuencia es que todas las relaciones causales estén indicadas. Esto se define por medio de la teoría. De esta manera, es igualmente importante definir porque se incluye, como porque se excluye una relación entre variables (Hair et al, 1999).

La estimación del modelo se puede hacer por medio de regresión de mínimos cuadrados ordinarios, aunque en general se utiliza la estimación máximo verosímil, la cual es eficiente y no sesgada cuando se cumplen los supuestos de normalidad multivariante (Hair et al, 1999).

Normalmente los modelos causales se utilizan con variables de intervalo o razón, con un rango de puntajes suficientemente amplio. Sin embargo, según Kline (1998), en algunos casos es posible utilizar variables nominales u ordinales.

Otro tema relevante es que estos modelos permiten analizar efectos directos e indirectos de una variable sobre otra. A su vez, los efectos totales son la suma de ambos efectos (Kline, 1998).

Existen varias estrategias de modelización (Byrne, 2001; Hair et al, 1999; Kline, 1998):

- **Estrategia de modelización confirmatoria.** El investigador especifica un modelo aislado y usa un modelo causal para evaluar su significación estadística.
- **Estrategia de modelos rivales.** Dado que varios modelos pueden ofrecer ajustes iguales, este medio permite evaluar el modelo estimado con modelos alternativos, comparándolos.
- **Estrategia de desarrollo del modelo.** Aunque se propone un modelo, el propósito es mejorarlo a través de modificaciones, ya sea del modelo de medida o estructurales. Esto permite evaluar perspectivas con respecto a su especificación.

❖ Tipos de modelos

Los autores distinguen entre tres tipos de modelos causales (Kline, 1998; Byrne, 2001):

- **Path Analysis.** Estos son modelos que tienen solamente variables observadas y modelos estructurales. Pueden utilizar múltiples variables exógenas y endógenas. Las variables endógenas se pueden afectar entre sí. En este caso, solamente existe una hipótesis sobre la relación causal entre las variables y solamente existe una medición para cada variable. Se le agregan disturbios, los cuales son todas las causas de una variable endógena que se encuentran omitidas del modelo.
- **Análisis Factorial confirmatorio.** Estos modelos trabajan con modelos de medición, donde hay una diferencia explícita entre variables observadas y

latentes. Pueden utilizar múltiples variables latentes exógenas. El investigador determina la relación entre factores e indicadores.

- **Modelos híbridos.** Estos son modelos que combinan modelos de medición y estructurales. Pueden utilizar múltiples variables exógenas y endógenas, las cuales pueden ser latentes u observadas.

Otra distinción relevante es entre modelos recursivos y no recursivos. Los modelos no recursivos son aquellos donde los errores no se encuentran correlacionados y todos los efectos causales son unidireccionales. Los modelos recursivos son aquellos donde ocurren bucles de retroalimentación y donde puede haber errores correlacionados. Los modelos recursivos son más complicados, por lo que pueden requerir más supuestos (Berry, 1984; Kline, 1998). Kline (1998) afirma que para trabajar con modelos recursivos no se puede utilizar mínimos cuadrados ordinarios, sino solamente una estimación máximo verosímil.

Es importante destacar que en la literatura inglesa se habla de modelos recursivos en el caso de los que no existen bucles de retroalimentación. Sin embargo, para esta investigación, recursivo significa que los efectos pueden retroactuar sobre las causas y, por lo tanto, que los modelos pueden ser circulares.

❖ **Supuestos de la técnica**

Los supuestos de esta técnica son variados, y muchas veces, difíciles de cumplir:

- Observaciones independientes (Hair et al, 1999).
- Muestra aleatoria de encuestados (Hair et al, 1999).
- Linealidad en las relaciones (Hair et al, 1999; Kline, 1998).
- Normalidad multivariante. Es bastante sensible a las características distribucionales de los datos (Hair et al, 1999).
- Los datos ausentes pueden tener un importante efecto sobre el cálculo de la matriz de entrada de los datos (Hair et al, 1999). Debieran distribuirse azarosamente (Kline, 1998).
- Kline (1998) afirma que los modelos causales son una técnica de muestras grandes. El tamaño puede depender de muchos factores. Sin embargo, a

modo general, se afirma que prácticamente no es posible hacer un análisis de este tipo con menos de 100 casos. Entre 100 y 200 sería una muestra mediana y mayor que 200 una grande. Según Hair et al (1999) el tamaño de la muestra debe ser por lo menos tan grande como el número de covarianzas y correlaciones de la matriz de datos de entrada. Un mínimo habitual son cinco encuestados para cada parámetro estimado, sin embargo, un ratio de 10 es más apropiado. Por lo tanto, al ir aumentando la complejidad, aumentan los requisitos.

- Los residuos tienen una media igual a cero y son independientes, se distribuyen normalmente y tienen varianzas uniformes a través de los niveles de x , es decir, son homeostáticos (Kline, 1998)
- Hay que cuidar de que no exista multicolinealidad (Asher, 1983; Kline, 1998).
- Hay que eliminar casos aberrantes (Kline, 1998).

Además, cuando se trabaja con Path Analysis y se quiere asumir una relación de tipo causal, se deben cumplir los siguientes supuestos:

- Asociación suficiente entre dos variables (Asher, 1983; Hair et al, 1999)
- Antecedentes temporales de la causa frente al efecto (Asher, 1983; Hair et al, 1999). Dado que no se utilizan modelos experimentales, ambas variables se miden al mismo tiempo. Por esta razón, es necesario introducir otros criterios para determinar que esto se cumpla (Kline, 1998).
- Falta de alternativas a las variables causales. Eliminación de otros factores (Hair et al, 1999; Asher, 1983).
- Kline (1998) afirma que hay que tomar en cuenta posibles efectos de interacción de terceras variables porque estas pueden hacer que una relación no aparezca. También hay que tener cuidado con posibles relaciones espurias.
- Base teórica para la relación (Hair et al, 1999).
- La dirección de la causalidad debe estar claramente determinada (Kline, 1998).

Tal vez el aspecto más complejo de zanjar en los modelos de ecuaciones estructurales sea el de la identificación. Este problema hace referencia a la incapacidad del modelo para generar estimaciones aisladas (Hair et al, 1999). La complejidad de la identificación reside, según Kline (1998) en que puede ser que un

modelo funcione teóricamente pero luego empíricamente no lo haga. La identificación es especialmente compleja en el caso de los modelos recursivos.

El número de observaciones tiene que ser mayor al número de parámetros. Los grados de libertad deben ser mayores o iguales a cero. Un modelo identificado tiene cero grados de libertad y una única solución posible. Sin embargo, si bien ofrece un ajuste perfecto, la solución no tiene interés dado que no es posible de ser generalizada. Un modelo sobreidentificado es el objetivo de todos los modelos. La matriz de datos tiene más información que el número de parámetros a estimar, por lo que tiene un número de grados de libertad positivo. El investigador busca que el modelo tenga un ajuste aceptable con el mayor grado de libertad posible para que el modelo sea generalizable. Un modelo que no alcanza la condición de orden es uno infraestimado o no identificado. Este modelo tiene grados de libertad negativos, por lo que intenta estimar más parámetros de lo que permite la información disponible. Es matemáticamente imposible obtener una solución para un modelo no identificado. En este caso, es necesario fijar alguno de los parámetros (Asher, 1983; Byrne, 2001; Hair et al, 1999; Kline, 1998). Otra opción es eliminar una flecha o agregar variables (Kline, 1998).

Para lograr la identificación del modelo hay que preocuparse de tres condiciones necesarias pero no suficientes:

- **Deben de existir por lo menos tantas observaciones como parámetros** (Kline, 1998).
- **Condición de orden.** Es una regla de conteo que se le aplica a todas las variables endógenas de modelos recursivos con todas las posibles correlaciones de errores. Se compara el número de variables observadas que tienen efecto directo en las variables endógenas con el número de las que no. A esto se le denomina variables excluidas. Esta condición requiere que el número de variables excluidas para cada variable endógena sea igual o mayor al número total de variables endógenas menos 1 (Kline, 1998).
- **Condición de rango.** Según esta condición, el investigador debe determinar si cada parámetro se estima de manera específica. Sin embargo, los autores afirman que este es un ejercicio complejo (Hair et al, 1999).

En el caso de modelos recursivos, no es necesariamente cierto que si se tiene un número de observaciones igual al de parámetros se pueda obtener una solución. Esto ocurre por ejemplo en el caso de la multicolinealidad, donde si bien hay más información, esta se repite. Una posible solución es agregar nuevas variables exógenas (Kline, 1998).

❖ Evaluación del Modelo

La calidad del modelo se evalúa por medio de varios aspectos. Uno de ellos es el ajuste del mismo. Existen medidas de ajuste absoluto del modelo, medidas de ajuste incremental y medidas de ajuste de parsimonia. Las medidas absolutas evalúan solo el ajuste del modelo como un todo, mientras que las medidas de ajuste incremental permiten evaluar el modelo propuesto con otro especificado por el investigador. Por último, los de parsimonia ajustan la medida de ajuste de manera de poder comparar modelos con diferente número de coeficientes estimados. A partir del análisis de estos coeficientes es posible reespecificar el modelo (Hair et al, 1999). Algunos coeficientes utilizados son el GFI (Goodnes of fit index), el AGFI (Adjusted Goodnes of fit index), los cuales van de 0 a 1, siendo 1 el ajuste perfecto. Son similares al R^2 , por lo que muestran la proporción de covarianza observada que es explicada por las covarianzas del modelo. El NFI (Normed fit index) indica la proporción de mejora en el ajuste total del modelo del investigador con respecto a un modelo de independencia o de hipótesis nula, en el cual se asume que las variables observadas no se encuentran relacionadas. Se interpreta como porcentaje de mejora (Kline, 1998). El R^2 permite evaluar la proporción de varianza explicada por el modelo (Asher, 1983). El chi cuadrado es otra manera de estimar el ajuste del modelo. Sin embargo, es muy sensible al tamaño muestral, por lo que con muestras grandes, cualquier diferencia resulta significativa.

Los coeficientes nombrados solamente permiten analizar el modelo como un todo. Si se quiere observar la relación entre algunas variables, se pueden analizar los coeficientes de regresión. Con respecto a estos, es difícil afirmar cuando un efecto es significativo, porque depende del tamaño de la muestra. Sin embargo, es posible afirmar que bajo 0.1 es bajo, alrededor de 0.3 es medio y sobre 0.5 es alto (Kline, 1998).

❖ Modelos Causales y complejidad

Se puede afirmar que los modelos causales presentan características complejas por varias razones:

- **Multicausalidad.** Según Berry (1984), muchos científicos sociales sugieren que existen ciertas relaciones entre variables que son demasiado complejas como para ser reflejadas en un modelo de una sola ecuación. De hecho, los modelos con múltiples ecuaciones han sido usados cada vez con mayor frecuencia en la investigación social, con resultados muy buenos. Por lo tanto, la posibilidad de trabajar con sistemas de ecuaciones, implica asumir que la realidad es multicausal.
- **Interacciones.** Los modelos causales permiten incorporar interacciones entre las múltiples variables. De esta manera, dos variables independientes pueden tener un efecto conjunto sobre una variable dependiente.
- **Holismo.** Según Kline (1998), los modelos causales permiten evaluar el modelo entero, lo cual permite integrar una visión a nivel macro en el análisis, más que una visión micro. Si bien los estadísticos a nivel de dos variables específicas son de interés, lo que prima es la preocupación por generar un buen modelo a nivel global.
- **Error.** Los modelos causales permiten incorporar los errores en la ecuación, ya sea los errores de especificación o de medición. De esta manera, no solamente se puede plantear un modelo con cierta capacidad de explicación, sino que se puede analizar cuanto error presenta y asociado a qué variable.
- **Recursividad.** Tal vez lo más fundamental es que los modelos causales tienen la posibilidad de incluir relaciones recursivas y de esta manera asumir que causa y efecto no son linealmente dependientes entre sí, que el efecto puede influir y, de alguna manera retroalimentar, la causa y generar procesos circulares.

Los modelos causales son parte de lo que podría denominarse como estadística clásica, la cual es uno de los métodos utilizados en la ciencia clásica. En este sentido, se entiende que son incapaces de trabajar con relaciones no lineales y que por lo tanto, asumen cierto determinismo en las relaciones. Sin embargo, es posible

afirmar que los modelos causales incorporan, en cierta medida, aspectos de la causalidad compleja, como son las interacciones, el papel del error, la incorporación de múltiples causas y una mirada enfocada en el todo. Evidentemente, esto ocurre en mayor medida en los modelos recursivos. Esto último es muy relevante para las ciencias sociales, donde en muchas ocasiones resulta muy difícil discernir temporalmente causa y efecto y donde muchos aspectos interactúan en generar algún resultado.

3.2 Las Redes Neuronales Artificiales

❖ Generalidades

Las Redes Neuronales Artificiales (RNA de ahora en adelante) pueden ser analizadas desde dos perspectivas. Por un lado, son una analogía al sistema biológico, imitando las redes neuronales. Por el otro, son una técnica de procesamiento con ciertas características que la diferencian de las técnicas clásicas.

Para efectos de este trabajo, interesa la segunda perspectiva. De esta forma, se dejará fuera del análisis una parte muy ligada a las RNA, que es la inteligencia artificial. En este caso, solamente interesan las RNA en cuanto a sus características que permiten afirmar un mayor acercamiento a la teoría de la complejidad.

Leiva, Rioja y Veneros (2002) definen las RNA como un sistema computacional multiprocesador que tiene las características de ser un procesamiento simple de elementos, con un alto grado de interconexión, una escala simple de mensajes y una interacción adaptativa entre elementos. Las RNA intentan imitar tres aspectos de los sistemas nerviosos: el paralelismo de cálculo, la memoria distributiva y la adaptabilidad al entorno. Por lo tanto, las RNA son sistemas paralelos, distributivos y adaptativos.

Leiva et al (2002) describen las principales características de las RNA:

- **Auto Organización y Adaptabilidad.** Por medio de algoritmos de aprendizaje adaptativos y de autoorganización, se logra un procesamiento robusto y flexible. Las RNA son capaces de adaptarse al entorno.
- **Procesado No Lineal.** Las RNA no tienen un procesamiento lineal, lo que aumenta su capacidad para aproximar y clasificar. Por su parte, aumenta su inmunidad frente al ruido.
- **Procesado Paralelo.** Se utilizan muchas células de procesamiento debido al alto nivel de interconectividad.

Montaño y Palmer (2002) afirman que las RNA tienen una capacidad admirable para procesar datos con ruido o incompletos. A su vez, tienen una alta tolerancia a los fallos, es decir, para operar con conexiones dañadas. Por último, son capaces de responder a tiempo real por su paralelismo. Leiva et al (2002) afirman que las RNA son muy versátiles y capaces de aprender, por lo que se convierten en los mejores métodos de predicción. De hecho, Garson (1998) afirma que se ajustan bien para trabajar en tópicos sociales, donde la información de las variables independientes está incompleta y los pronósticos son aproximaciones.

Por otro lado, Garson (1998) afirma que las RNA tienen varios obstáculos. Si bien sirven para la predicción, no sirven para el análisis causal. Segundo, son demasiadas las RNA que existen y son muy complejas. Tercero, se han demorado en ser incorporadas en programas computacionales. Cuarto, en las ciencias sociales tienden a generar confusión, por lo que no son utilizadas. Una de las causas de esto último, es que incorporan un lenguaje totalmente distinto al de la estadística convencional.

Montaño (2002) afirma que estas técnicas se han ido consolidando como un nuevo campo dentro de las ciencias de la computación. Las RNA se orientan a la clasificación de patrones y a la estimación de variables continuas. Garson (1998) nombra los siguientes usos de las RNA: problemas de clasificación, problemas de completación, análisis alternativos al análisis factorial y discriminante, problemas de predicción, especialmente cuando la relación no es lineal.

❖ **Composición y funcionamiento de las RNA**

Las RNA están compuestas de nodos de neuronas interconectadas que se encuentran estructuradas en una red. Esta red tiene capas de entrada, de salida y una o más capas ocultas. La capa de entrada recibe información (o input) de otras neuronas o desde el exterior. Las unidades ocultas son las que procesan datos. El número de unidades ocultas se determina por medio de un método de prueba y error. Por último, las unidades de salida son el resultado de la red, esto es, el output asociado a las variables dependientes. Las variables de entrada y salida son normalmente binarias o continuas (Leiva et al, 2002).

Las neuronas artificiales son procesadores elementales, que a partir de un vector de entrada proporcionan una única respuesta. Estas neuronas se conectan por medio de un patrón de enlace o arquitectura. Las neuronas se agrupan en capas. El conjunto de capas es una red. Las conexiones entre las neuronas pueden ser excitatorias o inhibitorias. Esto depende del peso sináptico asociado a la conexión. Un peso sináptico positivo determina una conexión excitatoria, mientras que uno negativo, una inhibitoria (Leiva et al, 2002). Las conexiones inhibitorias tienden a prevenir la activación de una neurona y las excitatorias causan la activación (Garson, 1998). Por medio de una fase de aprendizaje se obtiene un peso sináptico, el cual está compuesto de un signo y una magnitud (Leiva et al, 2002). Las neuronas pasan datos de una a otra, ajustando los valores de acuerdo a la lógica que se les asigna. Los pesos sumados se pasan a la siguiente capa de neuronas por medio de una función de activación, la cual convierte este peso en un valor de activación, también llamado peso de transferencia. Si este valor se encuentra sobre un valor umbral, la neurona va a activar la próxima y resultar en un output (Garson, 1998)

A su vez, se puede distinguir entre conexiones intracapa e intercapa. La conexión intracapa se da entre neuronas de una misma capa, mientras que la intercapa se da entre neuronas de diferentes capas. Una conexión realimentada ocurre cuando una conexión tiene el sentido inverso a la entrada-salida. Incluso es posible, en algunos casos, que una neurona se realimente a sí misma (Leiva et al, 2002).

❖ Clasificación de las RNA

Es posible clasificar las RNA según una serie de criterios:

- **Según el número de capas.** Se puede distinguir entre Monocapas, las cuales solamente tienen una capa de nodos y multicapa, las cuales contienen muchas capas ocultas (Pérez y Martín, 2003).
- **Según la conectividad.** Entre las redes multicapa existen dos variantes, las RNA totalmente conectas, donde todas las neuronas de cada capa se conectan con todas las de otras capas y las RNA parcialmente conectadas, donde solamente algunas neuronas de la capa oculta están conectadas a la capa de entrada (Leiva et al, 2002).
- **Según el flujo de datos de la red.** Es posible clasificar las RNA en unidireccionales (feed forward) y redes recurrentes (feedback). En las unidireccionales hay flujo de información solamente hacia un sentido, mientras que en las recurrentes, la información puede circular en cualquier sentido, incluso retroalimentar la capa de entrada con datos de la capa de salida (Leiva et al, 2002). Según Pérez y Martín (2003), esto último se utiliza cuando se le quiere dar un carácter temporal a la red.
- **Según el modo de comunicación.** Es posible clasificar las redes en hieráticas, en las cuales las neuronas de una capa más abajo solo pueden comunicarse con las del siguiente nivel y resonancia, en las cuales existen conexiones bidireccionales y se pueden mandar mensajes varias veces hasta que una condición es alcanzada (Leiva et al, 2002).

❖ Aprendizaje

Las RNA aprenden por medio de algoritmos que van cambiando sus pesos sinápticos durante un proceso de entrenamiento, hasta encontrar una solución al problema (Hinton, 1992; Leiva et al, 2002;). Es posible distinguir entre dos fases del aprendizaje. Por un lado, se encuentra la etapa de entrenamiento y por el otro, una de recuerdo o ejecución. En la primera, la red aprende a resolver un problema por

medio de la actualización de los pesos. En la segunda se obtienen salidas (Pérez y Martín, 2003).

Existen principalmente cuatro modos de aprendizaje o entrenamiento:

- **Aprendizaje No Supervisado.** En este modo, las neuronas ocultas deben ser capaces de aprender a organizarse sin ayuda externa. Por lo tanto, se le presentan entradas, pero sin información de las salidas ideales, para poder comparar su predicción. La red descubre regularidades por medio de una regla de aprendizaje. Estas redes reconocen patrones en los datos de entrada y crean categorías a partir de estos (Garson, 1998; Leiva et al, 2002; Pérez y Martín, 2003).
- **Aprendizaje Supervisado.** En este caso, se le proporcionan a la red parejas de patrones entrada-salida y esta aprende a asociarlas. De esta manera, por medio de un proceso iterativo, se ajustan los pesos hasta que las salidas sean las deseadas. Existen dos maneras para guiar este entrenamiento. Por un lado, se puede corregir a partir de una decisión y la otra, a partir de una optimización de un criterio de costo (Leiva et al, 2002; Pérez y Martín, 2003).
- **Aprendizaje reforzado.** Este es un aprendizaje que utiliza un método de prueba y error buscando maximizar un índice de desempeño llamado señal de reforzamiento. A la red se le da información de que tan bien o mal lo está haciendo, sin darle la salida deseada (Garson, 1998; Leiva et al, 2002). De esta manera, es posible afirmar que se encuentra entre el aprendizaje supervisado y no supervisado, ya que solamente se le da una medida del éxito o fracaso global de la red para que esta actualice los pesos, sin dar información del error para elementos individuales (Pérez y Martín, 2003)
- **Aprendizaje híbrido.** También es posible utilizar aprendizaje supervisado y no supervisado en distintas capas (Leiva et al, 2002; Pérez y Martín, 2003).

Luego del entrenamiento, se procede a la etapa de recuerdo, en la cual se procesan los datos (Leiva et al, 2002; Pérez y Martín, 2003).

❖ **Las principales arquitecturas**

Existe un número enorme de distintos modelos (arquitecturas) de RNA. Debido a esto, solamente se presentarán las que son relevantes para un entendimiento histórico de la aparición de las RNA, así como las que son utilizadas más frecuentemente.

- **Modelo del Perceptrón.** Este modelo es el primer modelo que se inventó. Es un modelo unidireccional compuesto por dos capas de neuronas artificiales, una de entrada y una de salida. La salida es 1 cuando la activación de la neurona alcanza cierto criterio y es 0 en caso contrario. Es un dispositivo entrenable, dado que permite determinar los pesos sinápticos a partir de ejemplos. Por lo tanto, utiliza aprendizaje supervisado (Leiva et al, 2002; Pérez y Martín, 2003).
- **Modelo Adelina.** Es similar al perceptrón, pero tiene una respuesta de tipo lineal. Las entradas, a su vez, pueden ser continuas. Incorpora un parámetro denominado bias o umbral, el cual es distinto al umbral de disparo del perceptrón, dado que es un parámetro que le da un grado de libertad adicional a la neurona. Utiliza la regla de mínimos cuadrados que permite actualizaciones de tipo continuo. Esta actualización es proporcional al error que la neurona comete (Leiva et al, 2002; Montañó, 2002). El entrenamiento ocurre por medio de una presentación de un patrón de entrada. Luego se calcula la salida lineal y su diferencia con la salida esperada. Si el error cuadrático medio alcanza un valor determinado, se termina el aprendizaje. Adelina tiene solamente una neurona en la capa de salida. Madaline es la alternativa que tiene varias (Pérez y Martín, 2003)
- **Perceptrón Multicapa:** Minsky y Papert (en Pérez y Martín, 2003) modificaron el modelo del perceptrón introduciendo una capa adicional de neuronas entre la capa de entrada y de salida. Cada neurona incluye una no linealidad en el final de la salida. Por medio de las capas ocultas, la red puede aprender tareas complejas, extrayendo características más significativas de los patrones de entrada. Normalmente se entrena por medio del método de back propagation. De hecho, al usar esta arquitectura con back propagation, se suele hablar del Modelo de Back Propagation (Leiva et al, 2002).

- **Modelo de Retropropagación.** Pérez y Martín (2003) se refieren al modelo de retropropagación como un modelo independiente. En este caso, el número de capas y de neuronas son decisiones a tomar. Esta red funciona aprendiendo un conjunto de patrones de entrenamiento por medio de un ciclo de propagación y adaptación en dos fases. Primero, se asignan pesos pequeños aleatorios. Luego, se presenta una entrada y se propaga obteniendo una salida. Esta salida se compara con una salida esperada y se calcula un error para cada neurona de salida. Las señales de error se propagan desde la capa de salida hacia la capa intermedia. Los pesos se actualizan en base a esto. Este modelo se utiliza para la codificación de información, la traducción de textos hablados, el reconocimiento óptico de caracteres escritos, entre otros (Garson, 1998; Pérez y Martín, 2003). Según Garson (1998) este modelo es el más utilizado.
- **Modelo de Hopfield.** Son redes recurrentes de adaptación probabilística que aprenden a reconstruir patrones de entrada que memorizan durante el entrenamiento. Tienen una capa con conexión total (Leiva et al, 2002).
- **Modelo de Kohonen.** Esta red trabaja con mapas topológicos para establecer características comunes entre vectores de entrada a la red. Tiene solamente dos capas y un aprendizaje no supervisado. La capa de entrada recibe la información. Las neuronas de esta capa se conectan con las de la segunda capa. Esta segunda capa es una capa de competición, que realiza el procesamiento. Las neuronas compiten entre sí para responder, por lo que finalmente solo una se activa: la neurona ganadora. Esto se hace por medio de la determinación de qué neurona tiene los pesos mas próximos a la entrada. El objetivo es clasificar patrones de entrada en grupos de características similares, de manera que cada grupo active siempre las mismas salidas. Requieren la determinación del número de clusters de antemano (Garson, 1998; Leiva et al, 2002; Pérez y Marín, 2003).

❖ **Consideraciones metodológicas**

Existen una serie de decisiones que es necesario tomar al construir una RNA (Leiva et al, 2002):

- **Tamaño de la red.** Mientras más neuronas haya en la capa oculta, existe una mayor capacidad de memorización en la fase de entrenamiento. Sin embargo, en cierto momento empieza a disminuir la capacidad de generalización. El tamaño ideal se determina por experimentación (Leiva et al, 2002). Garson (1998) afirma que un mayor número de capas empeora el rendimiento tanto en términos de generalización como de tiempo de entrenamiento.
- **Utilización de capas ocultas.** Según Garson (1998) no trabajar con capas ocultas puede servir para problemas lineales, pero si la decisión es más difícil la capa oculta sirve. Sin embargo, si hay muchas capas ocultas, el modelo puede sobre entrenarse y peligrar la generalización. Pero si son muy pocas, no entrena bien.
- **Conexiones.** Es necesario determinar si el modelo tendrá conexiones intracapa, intercapas, unidireccionales o realimentadas (Leiva et al, 2002).
- **Conjunto de entrenamiento.** Esta muestra de datos tiene que cubrir todos los escenarios posibles, de manera de poder ser aplicado a todas las posibilidades. Otro tema relevante es la relación entre el tamaño del conjunto de entrenamiento y el número de pesos de la red. Si los primeros son menos que los pesos, se podría presentar una memorización de la solución y perderse la capacidad de generalización. Por lo tanto, se recomienda que el número de entrenamientos sea por lo menos el doble que los números de pesos. Al mismo tiempo, si no se alcanza convergencia, hay que aumentar el conjunto o crear ejemplos distintos (Leiva et al, 2002). Garson (1998) afirma que es mejor un número de datos de entrenamiento grande que uno chico.
- **Parámetros de aprendizaje.** El objetivo es entrenar lo más rápido posible y alcanzar el mejor rendimiento. A mayor tasa de aprendizaje, el tiempo es menor, pero al mismo tiempo, es posible que no se logre convergencia. Por lo tanto, se recomienda usar una tasa de aprendizaje grande al comienzo e ir la reduciendo hasta alcanzar los pesos sinápticos que utilizará el modelo (Leiva et al, 2002).

- **Criterios de detención.** Se pueden utilizar dos criterios para definir hasta cuando entrenar: definir el número de iteraciones o establecer un error final (Leiva et al, 2002).

❖ **RNA y la complejidad**

A diferencia de los Modelos Causales, las RNA son asumidas como una técnica de procesamiento diferente a la estadística clásica. De hecho, muchos autores han comparado las RNA con las técnicas de procesamiento clásicas, algunos afirmando que si bien son distintas, tienen un funcionamiento similar, y otros destacando sus diferencias.

Empezando con el procesamiento computacional, Montañó (2002) distingue el procesamiento de las RNA y el convencional de Von Neumann, según los siguientes puntos:

- Paso de un procesamiento secuencial, donde las transformaciones se realizan según una serie de instrucciones, a un sistema conexionista, el cual es paralelo y en el cual muchas unidades de procesamiento pueden funcionar simultáneamente.
- La memoria de la arquitectura de Von Neumann tiene un carácter discreto, compuesto por un gran número de ubicaciones físicas donde se almacenan las instrucciones y los datos. En cambio, en RNA la información se distribuye a lo largo de los parámetros del sistema
- La arquitectura convencional se programa, mientras que las RNA se entrenan. De esta manera, las RNA aprenden sin reglas concretas.
- El autor concluye que las RNA tienen la ventaja de resistir al funcionamiento defectuoso de alguna parte del sistema, dado que cada computación es simple. En los sistemas convencionales, un defecto puede echar a perder toda la computación. Esto implica, a su vez, que un modelo conexionista puede reconocer un objeto si bien solamente vea una parte del mismo.

El procesamiento de las RNA permite reducir el tiempo de cálculo, lo cuál es una ventaja comparativa (Pérez y Martín, 2003). Leiva et al (2002) afirman que los métodos estadísticos convencionales permiten conocer la distribución de las variables, los errores asociados, entre otros, pero son incapaces de aprender de estos últimos. Esto es hoy posible por medio de las RNA. A diferencia de los sistemas informáticos habituales, tienen la capacidad de procesar de manera paralela y masiva.

Pérez y Martín (2003) afirman que tanto las RNA como la estadística clásica buscan analizar datos. De hecho, las RNA siguen métodos estadísticos, como los mínimos cuadrados o el cálculo de distancias. La inferencia estadística en RNA significa aprender a generalizar a partir de datos con ruido. Por lo tanto, afirman que ambas debieran avanzar juntas para beneficiarse mutuamente.

Si bien se tiende a decir que las RNA no requieren de supuestos, Pérez y Martín (2003) afirman que las RNA implican la misma clase de hipótesis distribucionales que los modelos estadísticos. La diferencia está en que en estadística se analiza la importancia de transgredir estas suposiciones y en las RNA se tiende a ignorar. Al igual que en la estadística clásica, es necesario eliminar variables que no discriminan, eliminar casos aberrantes, convertir variables nominales en dummies y cuidar de la generalización de los datos si se quiere trabajar con otras poblaciones (Garson, 1998). Si se consideran estas suposiciones, se pueden lograr redes mucho mejores.

Montaño (2002) afirma que según análisis teóricos de las técnicas, ambas son muy parecidas, hasta idénticas. Sin embargo, utilizan términos distintos para nombrar el mismo objeto (ver Tabla 1).

El autor realiza, a su vez, un paralelo entre distintas técnicas. De esta manera, afirma que, por ejemplo, la Regresión y el Análisis Discriminante es equivalente al Aprendizaje Supervisado; la Reducción de Datos es equivalente al Aprendizaje no supervisado y el Análisis cluster al Aprendizaje competitivo. A su vez, un perceptrón simple puede ser considerado como un modelo lineal generalizado.

Tabla 1: Diferencias en nomenclatura Estadística Convencional y RNA

ESTADÍSTICA CONVENCIONAL	RNA
Observación	Patrón
Muestra	Datos de entrenamiento
Variables explicativas	Variables de entrada
Variables de respuesta	Variables de salida
Modelo	Arquitectura
Residual	Error
Error aleatorio	Ruido
Estimación	Entrenamiento, Aprendizaje
Interpolación	Generalización
Interacción	Conexión funcional
Coefficientes	Pesos de conexión
Constante	Peso umbral

Fuente: Montaña, 2002.

Montaña (2002) concluye que si bien se usan métodos de estimación distintos (mínimos cuadrados en el caso del perceptrón y máxima verosimilitud en el caso del Modelo lineal general), no se trata de metodologías contrapuestas, sino que existe un solapamiento entre ambos campos.

Varios autores compararon ambas técnicas en términos de su capacidad para obtener buenos resultados. Leiva et al (2002) compararon la capacidad predictiva de los modelos de RNA con modelos econométricos y concluyeron que los primeros tienen un rendimiento notablemente superior.

A su vez, Pitarque (en Montaña, 2002) comparó técnicas clásicas con RNA en tareas de predicción y clasificación. Los resultados obtenidos muestran que en predicción las RNA y los modelos de regresión múltiple tienden a rendir igual. Sin embargo, en clasificación las RNA rinden mejor en todo tipo de condiciones que los modelos estadísticos de análisis discriminante y regresión logística. Según el autor, en la mayoría de las situaciones las RNA son la técnica de elección para analizar la imputación de datos faltantes.

Varios autores (Garson, 1998; Montaña, 2002) concluyen que las RNA pueden ser mejores en el caso de datos ruidosos, incompletos, no lineales, entre otros. Montaña (2002) afirma que en temas de predicción, las RNA son muy útiles, especialmente cuando se introducen relaciones complejas o no lineales entre variables. Garson (1998), por su parte, sostiene que las RNA pueden ser mejores que los métodos estadísticos cuando los problemas no tienen una estructura discernible, los datos están incompletos y muchas variables independientes se relacionan de manera compleja y no lineal. El autor afirma que donde las redes neuronales son apropiadas, es posible que sean superiores a la estadística convencional para el reconocimiento de patrones. Funcionan incluso con datos ruidosos, sobrepuestos, altamente no lineales y discontinuos, porque el procesamiento se distribuye en muchas entidades de procesamiento, haciéndola tolerante a los errores. Por otra parte, no existe un límite al número de variables input, las cuales pueden incluir datos nominales. Dado que no trabaja con valores particulares, sino con patrones, no es terrible que existan errores de codificación, datos perdidos o ruido. Su naturaleza no paramétrica hace que sean especialmente adecuadas para datos de ciencias sociales, donde las suposiciones de normalidad y linealidad no pueden asegurarse. También son robustos cuando se trabaja con pocos datos.

Garsón (1998) concluye que son útiles para tres áreas amplias: clasificación y completamiento, predicción y control (toma de decisiones). La estadística clásica es más útil cuando los problemas tienen parámetros calculables. Las RNA pueden ser mejores cuando los problemas están poco estructurados, incluyen información incompleta, son ambiguos, incluyen sets de datos para aceptar soluciones aproximadas.

Este último planteamiento sustenta el argumento de que las RNA tienen características complejas en su funcionamiento y que, por lo tanto, permiten el trabajo con datos y relaciones complejas.

Entre las características de las RNA que se asocian a la complejidad encontramos:

- **Interacción.** A diferencia de las técnicas de regresión, las RNA no asumen la ausencia de interacción entre variables input, sino que pueden trabajar con efectos de interacción (Garson, 1998).
- **Holismo.** Capra (2003a) afirma que las redes neuronales permiten el trabajo con elementos interconectados, que pueden realizar millones de operaciones simultáneas y generar así propiedades globales. De esta manera, es posible asociar esta técnica con características globales.
- **Visión Sistémica.** A su vez, Situngkir (2003) llega a proponer las redes neuronales como modelo para entender la complejidad de lo social. El autor utiliza las RNA para estudiar la teoría de la estructura social. En este sentido, afirma que las RNA se adaptan para estudiar condiciones de estructuración. La acción humana se representaría por una neurona y la sociedad como la red completa.
- **Interconexiones.** De hecho, las RNA están compuestas de neuronas interconectadas entre sí. De esta manera, asimilan el funcionamiento de un sistema que corresponde a la interconexión de sus componentes.
- **Ruido.** Las RNA permiten trabajar con ruido, debido a su manera de procesar la información.
- **Datos perdidos.** Las RNA permiten trabajar con datos perdidos, debido a su manera de procesar la información.
- **No linealidad.** Las RNA no requieren que los datos sean lineales para poder analizarlos. Esto es una gran ventaja si se asume que la realidad, y especialmente la realidad social, es en su mayoría, no lineal.
- **Multicausalidad.** Las RNA no tienen un límite al número de variables que se introducen como input. Esto permite trabajar en una realidad que se asume multicausal.
- **Retroalimentación.** Las RNA permiten la existencia de relaciones entre neuronas que van desde la capa de salida hacia atrás, de manera de poder retroalimentar a las capas anteriores con respecto a su rendimiento.
- **Adaptación.** Las RNA utilizan algoritmos de aprendizaje adaptativos y de autoorganización, con los cuales logran adaptarse al entorno (Leiva et al, 2002).

Por lo tanto, si bien las RNA pueden tener muchos aspectos en común con la estadística clásica, se diferencian en varios de los aspectos que se critican de la ciencia clásica, como el uso solamente de relaciones lineales, la eliminación del ruido, la visión analítica, entre otros. De esta manera, es posible concluir que las RNA presentan características complejas en su funcionamiento.

A su vez, comparando los Modelos Causales y las Redes Neuronales Artificiales, se puede afirmar que los Modelos Causales Recursivos presentan un nivel mayor de complejidad que los Modelos Causales No Recursivos y que, a su vez, las Redes Neuronales presentan un nivel mayor de complejidad que el primero.

V. Marco Metodológico

1. Tipo de investigación

Este estudio tiene un carácter de comparación y evaluación de distintas metodologías de análisis de datos. En este sentido, cabe destacar que es una investigación sobre la técnica misma. Es un estudio cuantitativo, tanto en el sentido de analizar técnicas cuantitativas, como también por el hecho de utilizar criterios estadísticos para su comparación. Tiene un carácter no experimental, dado que no se controlan variables, sino que se utilizan bases de datos.

Dado que el objeto de esta investigación es de comparación de técnicas, y que por lo tanto no interesa describir ninguna población en especial, se utilizarán bases de datos secundarias, que presenten las características necesarias para el análisis.

2. Diseño de la investigación

Se contrastan cada vez dos técnicas de análisis de datos: una denominada como técnica estadística clásica y otra técnica estadística con características complejas. Ambas técnicas son utilizadas en ámbitos distintos, distinguiendo el nivel de complejidad de los mismos. La complejidad de las relaciones entre variables es determinada en base a un Instrumento de Diagnóstico de la Complejidad de las Relaciones entre Variables, presentado a continuación. De esta manera, se seleccionan datos que puedan ser diferenciados según su nivel de complejidad. Se analiza una relación entre variables de baja complejidad, una de mediana complejidad y una de alta complejidad. Para la comparación se utilizan criterios estadísticos que permiten afirmar cuál de las dos técnicas logra, con los mismos datos, mejores resultados.

Por una parte, se analiza la capacidad de Modelos Causales No Recursivos (técnica estadística clásica) con respecto a Modelos Causales recursivos (técnica estadística con características complejas). En este caso, se utiliza como criterio el

porcentaje de varianza explicada por cada modelo (R^2) y el CFI, como criterio de ajuste del modelo.

Segundo, se compara la Regresión Lineal (técnica estadística convencional) con Las Redes Neuronales Artificiales (técnica estadística con características complejas) en términos de su capacidad predictiva. En algunos casos se utiliza la Regresión Lineal Simple y en otros la Múltiple, dependiendo del número de variables a ingresar. Se utilizará como criterio el R^2 .

Las comparaciones se resumen en la siguiente Tabla (ver Tabla 2):

Tabla 2: Comparaciones entre Técnicas

TIPO DE RELACIÓN ENTRE VARIABLES	TÉCNICAS A COMPARAR	NÚMERO DE COMPARACIÓN
Relación entre variables de Baja Complejidad	Regresión Lineal	Comparación 1
	Redes Neuronales Artificiales	
Relación entre variables de Mediana Complejidad	Modelo Causal no recursivo	Comparación 2
	Modelo Causal recursivo	
Relación entre variables De Alta complejidad	Regresión Lineal	Comparación 3
	Redes Neuronales Artificiales	
Relación entre variables De Alta complejidad	Modelo Causal no recursivo	Comparación 4
	Modelo Causal recursivo	
Relación entre variables De Alta complejidad	Regresión Lineal	Comparación 5
	Redes Neuronales Artificiales	

En el caso de la relación entre variables de baja complejidad solamente se compara la Regresión Lineal con las Redes Neuronales Artificiales. Esto se hace, dado que una relación para ser lo más simple posible, implica no incluir más que una variable independiente y una dependiente. Este modelo no puede ser analizado por medio de Modelos Causales, dado que estos, para lograr sobreidentificación, requieren más de dos variables.

3. Etapas del estudio

El estudio se lleva a cabo por medio de las siguientes etapas:

- Elaboración de un Instrumento de Diagnóstico del Nivel de Complejidad de la Relación entre Variables.
- Búsqueda de relaciones entre variables que tengan un nivel de complejidad de baja, mediana y alta.
- Aplicación de las técnicas a las relaciones seleccionadas.
- Contrastación de los estadísticos de manera de responder a las hipótesis.
- Elaboración de recomendaciones con respecto al uso de las distintas técnicas.

4. Carta Gantt

A continuación se presenta la Carta Gantt del estudio completo (Tabla 3):

Tabla 3: Carta Gantt

	Abril				Mayo				Junio				Julio				Agosto				Sept.				Oct.				Nov.				Dic.			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
Recopilación de antecedentes	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■																				
Elaboración del Marco Teórico																	■	■	■	■	■	■	■	■	■	■	■	■								
Elaboración del Marco Metodológico y selección de los datos a utilizar																									■	■	■	■								
Aplicación de las Técnicas																													■	■	■	■				
Elaboración de Conclusiones y Recomendaciones																																				
Revisión																																				
Entrega de Tesis																																				

5. Relevancia

Esta investigación tiene una relevancia principalmente *metodológica*. Se contrastan técnicas clásicas con técnicas que presentan características complejas, de manera de poder concluir con respecto a su capacidad predictiva. Este paso es fundamental para poder complementar la teoría de la complejidad con una metodología que permita el análisis empírico de la realidad social. En este sentido, esta investigación aporta al conocimiento de posibles métodos de la complejidad.

A su vez, dado que para llevar a cabo este análisis es necesario determinar el nivel de complejidad de relaciones entre variables, se elabora un instrumento para diagnosticar el nivel de complejidad de las relaciones entre variables. De esta manera, otro aporte de esta investigación es la creación de un instrumento que permite discriminar entre distintas relaciones entre variables y de esta manera, ayudar a la toma de decisiones con respecto a la técnica que debe ser usada.

6. Instrumento de Diagnóstico del Nivel de Complejidad de las Relaciones entre Variables

A partir de los aspectos centrales de la complejidad, definidos en el capítulo de conclusión de las teorías de la complejidad –especialmente con respecto a la causalidad compleja-, se definen una serie de criterios que permiten discriminar según el nivel de complejidad de una relación entre variables. Sin embargo, cabe destacar que este es el primer instrumento de este tipo que se desarrolla, y por lo tanto, tiene un aspecto exploratorio. De esta manera, se plantea la posibilidad de seguir desarrollándolo y mejorándolo en el futuro.

La unidad a ser clasificada según complejidad son relaciones entre variables y no variables como tal, dado que, por un lado, muchas de las características de la complejidad tiene que ver con relaciones, efectos e interacciones, y por el otro, porque las técnicas que se utilizan no son descriptivas, sino de relaciones entre variables.

Sin embargo, no todas las características de la complejidad tienen su correlato en el análisis de datos. Por lo tanto, sólo se toman en cuenta aquellas que efectivamente se pueden observar en las relaciones entre variables, ya sea con criterios teóricos o pruebas técnicas.

A continuación se presentan los criterios definidos y su operacionalización, de manera de poder construir un instrumento a ser utilizado de manera objetiva para definir el nivel de complejidad de las relaciones entre variables. Sin embargo, es necesario destacar que estos criterios se evalúan en términos de grados de cumplimiento. Por esta razón, se definen para cada criterio tres niveles: bajo (0), medio (1) y alto (2). En varios casos estos niveles son determinados según criterios que pueden sonar arbitrarios, sin embargo, es necesario definir el corte en algún lugar. Cada relación entre variables es categorizada, de esta manera, según el nivel de complejidad para cada criterio. El instrumento final, por lo tanto, presenta puntajes entre 0 (baja complejidad) y 12 (alta complejidad). De esta manera, una relación es más compleja mientras cumpla un mayor número de criterios y los cumpla en una mayor medida.

- 1. Recursividad.** La recursividad hace alusión, en este caso, a que no sea posible afirmar que efectivamente el efecto es anterior a la causa y que por lo tanto, no haya una secuencia temporal clara. En el caso de la recursividad, puede ser que causa y efecto se influyan mutuamente o que operen en forma circular, retroalimentándose mutuamente. Por lo tanto, se analiza si existen indicios de que la causa tenga una incidencia retroactiva en el efecto. Una relación recursiva presenta un mayor nivel de complejidad.

Las categorías son:

- (0) Bajo: No existen relaciones recursivas o estas son insignificantes.
- (1) Medio: Existen relaciones recursivas pero estas no son determinantes, ni modifican la relación.
- (2) Alto: Las relaciones recursivas influyen significativamente en la relación, modificándola.

2. Errores de medición y Ruido. Los errores de medición y el ruido implican que las relaciones no son tan limpias como debieran y que el error, por lo tanto, es alto. Esto ocurre especialmente en el caso de datos sociales en los cuales se intenta dar cuenta de fenómenos complejos por medio de constructos. De esta forma, mientras el constructo sea más complejo, y por lo tanto pueda tener problemas de confiabilidad, mientras más indirectas sean las mediciones –como es el caso de una encuesta que no observa directamente un fenómeno- y mientras más le cueste al encuestado encontrar una respuesta a lo que se le está preguntando, mayor es la probabilidad de errores de medición y ruido. Mientras mayor es el ruido y los errores de medición, mayor es el nivel de complejidad.

Las categorías son:

- (0) Bajo: La medición se hizo por medio de observaciones directas.
- (1) Medio: La medición se hizo por medio de una encuesta, pero se miden variables simples.
- (2) Alto: La medición se hizo por medio de una encuesta y las variables son constructos complejos

3. Datos perdidos. Los datos perdidos, o missing data, tienen que ver con bases de datos incompletas. Esto ocurre frecuentemente en estudios por medio de encuestas, donde los encuestados deciden no contestar algunas de las preguntas. Los datos perdidos se analizan por medio del Análisis de Datos Perdidos del programa estadístico SPSS v.13. Mientras mayor es el porcentaje de datos perdidos, mayor es el nivel de complejidad.

Las categorías son:

- (0) Bajo: No existen datos perdidos
- (1) Medio: Existen datos perdidos pero son un porcentaje moderado (menores al 5%).
- (2) Alto: Existe un número significativo de datos perdidos (más del 5%).

4. Interacciones. Las interacciones hacen alusión al hecho de que dos variables independientes aumenten su efecto sobre una variable dependiente al aparecer juntas. Por lo tanto, se analiza la existencia de posibles interacciones. Dado que es prácticamente imposible que una relación entre variables se encuentre libre de interacciones, el análisis se realiza de manera gradual. Mientras más y mayores interacciones existan, mayor es el nivel de complejidad.

Las categorías son:

- (0) Bajo: No existen interacciones importantes en el modelo.
- (1) Medio: Existen interacciones, pero estas no son determinantes, ni modifican la relación.
- (2) Alto: Las interacciones influyen significativamente en la relación, modificándola.

5. Linealidad. La linealidad de la relación entre variables es determinada por medio de un ajuste de rectas, así como de manera visual, por medio del Ajuste de Curvas, del programa estadístico SPSS v.13. Una relación lineal es aquella donde una recta lineal ajuste a los datos, obteniendo un R^2 significativo. A su vez, esto implica gráficamente, que los datos se distribuyen en forma de una recta. Este análisis se realiza evaluando grados de linealidad. Mientras más lineal es una relación, mayor es su nivel de complejidad.

Las categorías son:

- (0) Bajo: La relación entre las variables es altamente lineal, con un porcentaje de varianza explicada significativa (R^2 mayores a 0,7).
- (1) Medio: La relación no es fuertemente lineal, con un peso en la variable dependiente solamente mediano (R^2 menores a 0,7 y mayores a 0,4). En el caso de modelos de varias variables, cuando existen algunas relaciones lineales y otras no lineales.
- (2) Alto: Existen relaciones fuertemente no lineales entre los datos (R^2 menores a 0,4).

6. Múltiples causas. El que una variable dependiente tenga múltiples causas es determinado analizando las posibles causas de un determinado fenómeno. De esta manera, una variable dependiente tiene múltiples causas si una variable única no explica una proporción de varianza suficientemente grande como para asumir existen pocos efectos diferentes que no están siendo tomados en cuenta. A mayor cantidad de causas, mayor es el nivel de complejidad.

Las categorías son:

- (0) Bajo: Es posible definir una causa que es determinante para explicar la variable dependiente. Presenta un porcentaje de varianza explicada muy alto, superiores a un R^2 de 0,7, mientras que no existen otras variables que tengan un efecto importante.
- (1) Medio: Si bien existe una variable independiente con un peso importante, se observan otras posibles causas, que explican un porcentaje no menor de la varianza restante. De esta manera, el R^2 se ubica entre 0,4 y 0,7.
- (2) Alto: Existen muchas posibles causas, por lo que las variables independientes tienen pesos solamente relativos sobre la variable dependiente (R^2 menores de 0,4).

7. Datos utilizados

a. Comparación 1: Regresión Lineal comparada con Redes Neuronales Artificiales - Relación entre Variables de Baja Complejidad


❖ Base de datos

Se utilizan datos experimentales de un estudio realizado por Felipe Grüttner, de la carrera de Ingeniería Civil Industrial y de Sistemas de la Universidad Gabriela Mistral². En este experimento se mide el voltaje y la corriente, variando los valores del voltaje. Se cuenta con 16 datos experimentales.

❖ Descripción del modelo según Regresión Lineal Simple

La ley de Ohm, una de las leyes fundamentales de la electromecánica, afirma que el voltaje se relaciona de manera positiva con el amperaje de la corriente que circula en un circuito.

De esta manera, el modelo planteado es el siguiente:



Las variables introducidas son las siguientes:

- **Voltaje:** Es la tensión de voltaje, medido en Volts (V).
- **Corriente:** Es la intensidad de corriente, medido en Amper (A)

² Manuscrito no publicado.

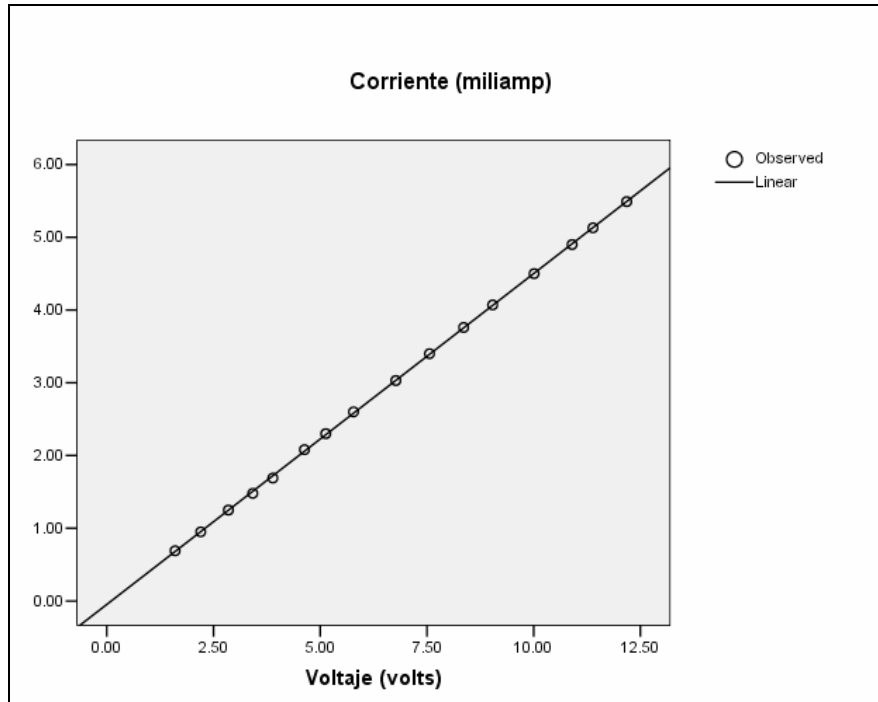
❖ Descripción del Modelos según Redes Neuronales Artificiales.

Para el caso de las RNA, se incorporan las mismas variables. Voltaje es la variable de input, mientras que la Corriente es el output que se busca predecir.

❖ Evaluación de los datos según el Instrumento de Diagnóstico de la Complejidad de relaciones entre variables.

A continuación se evalúa este modelo según los distintos criterios definidos anteriormente, de manera de evaluar su nivel de complejidad:

- 1. Recursividad.** El modelo no presenta efectos de recursividad, dado que la corriente no influye en el voltaje (el cuál es determinado por el experimentador). Por lo tanto, con respecto a este criterio, el nivel de complejidad es bajo (0).
- 2. Errores de medición y Ruido.** Los datos utilizados son observaciones directas, por medio de aparatos eléctricos. De esta manera, los errores de medición y ruido son bajos, teniendo un nivel de complejidad bajo (0).
- 3. Datos perdidos.** Las variables utilizadas no presentan datos perdidos. Por lo tanto, el nivel de complejidad según este criterio es bajo (0).
- 4. Interacciones.** Si bien es siempre posible que algo interaccione con el voltaje, el efecto es mínimo. La relación es prácticamente determinista. El nivel de complejidad según este criterio es bajo (0).
- 5. Linealidad.** La relación entre voltaje y corriente es perfectamente lineal. De hecho, el primero explica un 99,99% de la segunda (ver Gráfico 1). La complejidad, según este criterio, es baja (0).

Gráfico 1: Ajuste de Curvas Voltaje - Corriente

6. **Múltiples causas.** El voltaje tienen un efecto determinista sobre la corriente. Si bien la temperatura puede tener un efecto, se observa en el porcentaje de varianza explicado, que el voltaje presenta un efecto prácticamente determinista. Por lo tanto, queda descartado que la explicación de la variable corriente requiera de múltiples causas. Según este criterio, el nivel de complejidad de esta relación es bajo (0)

Analizando estos distintos aspectos queda en evidencia esta relación entre variables es de un nivel bajo de complejidad (0 de 12 puntos).

b. Comparación 2: Modelo Causal Recursivo comparado con Modelo Causal No Recursivo – Relación entre Variables de Complejidad Media

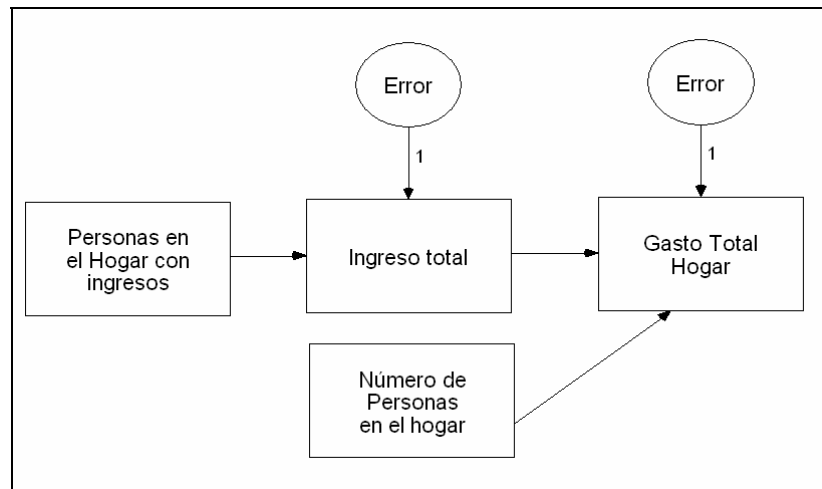
❖ Base de Datos

La base de datos utilizada para la relación entre variables simple, en el caso del modelo causal, es la Encuesta Nacional de Ingresos y Gastos de los Hogares del año 2005 del Instituto Nacional de Estadística, Geografía e Informática mexicano³. Esta encuesta recoge datos demográficos, económicos, de calidad de vida, entre otros, de hogares. La base de datos cuenta con información acerca de 23.174 hogares.

❖ Descripción del Modelo según un Modelo Causal no recursivo.

El modelo propuesto es el siguiente (ver Gráfico 2):

Gráfico 2: Modelo Causal No recursivo – Comparación 2



³ Base de datos obtenida de <http://www.inegi.gob.mx>

A continuación se describen las variables incorporadas en el modelo:

- **Gasto Total Hogar:** Incluye todos los gastos realizados por el hogar en un período determinado. De esta manera, se contabilizan los gastos en alimentos, vestuario, electricidad, entre otros. A su vez, se le suma autoconsumo, pago en especies, regalos y erogaciones financieras y de capital.
- **Ingreso Total Hogar:** incluye todos los ingresos que el hogar obtiene en un período determinado. Incluye ingresos, autoconsumo, pago en especie, regalos, estimación del alquiler e ingresos no monetarios.
- **Número de personas en el hogar:** Corresponde al número de personas que residen en el hogar.
- **Personas en el Hogar con ingresos:** Corresponde al número de personas en el hogar que perciben ingresos.

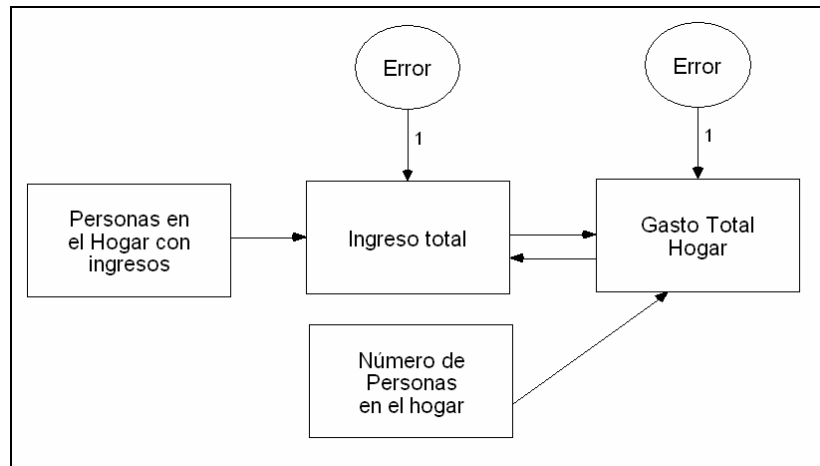
Estas variables se relacionan en el modelo de la siguiente manera:

El gasto que un hogar realiza es un resultado de sus ingresos totales, así como del número de personas que habitan en dicho hogar. A su vez, el monto de ingreso total se ve influenciado por el número de personas que perciben ingresos en el hogar. Si bien este es un modelo muy simplificado, sirve para los propósitos de este estudio por tener la característica de ser comparativamente muy simple.

❖ **Descripción del Modelo según un Modelo Causal recursivo.**

Este mismo modelo puede ser expresado de forma recursiva, de la siguiente manera (ver Gráfico 3):

Gráfico 3: Modelo Causal Recursivo – Comparación 2



En este caso, se está asumiendo que el gasto no es solamente la variable dependiente, sino que tiene un efecto, a su vez, en el ingreso.

❖ **Evaluación de los datos según el Instrumento de Diagnóstico de la Complejidad de relaciones entre variables.**

A continuación se evalúa el nivel de complejidad de esta relación, según los criterios definidos:

- 1. Recursividad.** El modelo propuesto no es recursivo, dado que el gasto que un hogar realiza no influye sobre su ingreso. Según este criterio, el nivel de complejidad es bajo (0).
- 2. Errores de medición y Ruido.** Si bien la base de datos fue construida por medio de una encuesta, lo que implica la posibilidad de existencia de errores de medición, los datos recogidos son simples. De esta manera, no existen errores por la operacionalización de conceptos ni por preguntar temas que pueden ser de

difícil respuesta. Las unidades son dinero y número de personas, las cuales son muy accesibles de contestar por parte de los encuestados. Por esta razón, el modelo debe tener relativamente menos errores de medición y ruido. Según este criterio, el nivel de complejidad es medio (1).

3. Datos perdidos. Las variables utilizadas no presentan datos perdidos. Según este criterio, el nivel de complejidad es bajo (0).

4. Interacciones. Si bien es imposible asumir una relación entre variables sin interacciones, la relación entre ingreso y gasto es bastante determinista, asumiendo que las interacciones no tienen un peso significativo. De esta manera, si bien el ingreso puede interaccionar con datos culturales, el primero es un dato muy estructural, y por lo tanto, de todas formas presenta un efecto directo sobre el gasto, independiente de otras variables. Por lo tanto, es posible asumir que esta relación se encuentra relativamente más alejada de las interacciones que otras variables sociales. Según este criterio, el nivel de complejidad es medio (1).

5. Linealidad. La relación entre ingreso y gasto se comporta de manera bastante lineal. En el Gráfico 4 se puede observar que a mayor ingreso, mayor gasto y que esta relación aumenta de manera proporcional. A su vez, el R^2 de esta relación es de 0,65, lo cuál permite afirmar que la recta se ajusta a los datos. Sin embargo, la relación entre el número de personas que habitan en un hogar y el gasto no es lineal (ver Gráfico 5). De hecho, el porcentaje de varianza explicada es del 0%. De esta manera, esta base presenta importantes relaciones no lineales. Según este criterio, el nivel de complejidad es alto (2).

Gráfico 4: Ajuste de Curvas Ingreso - Gasto

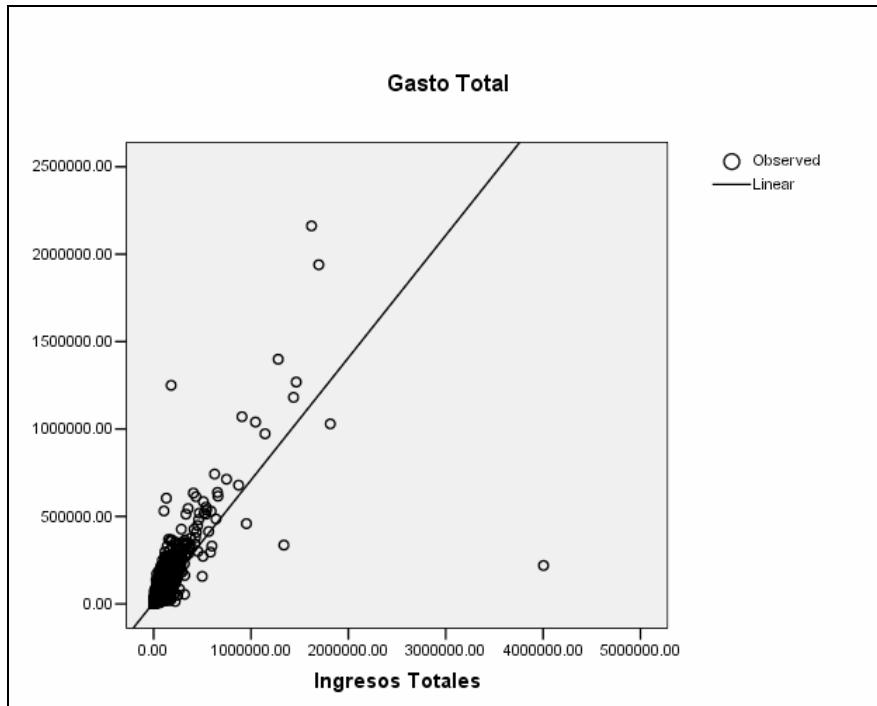
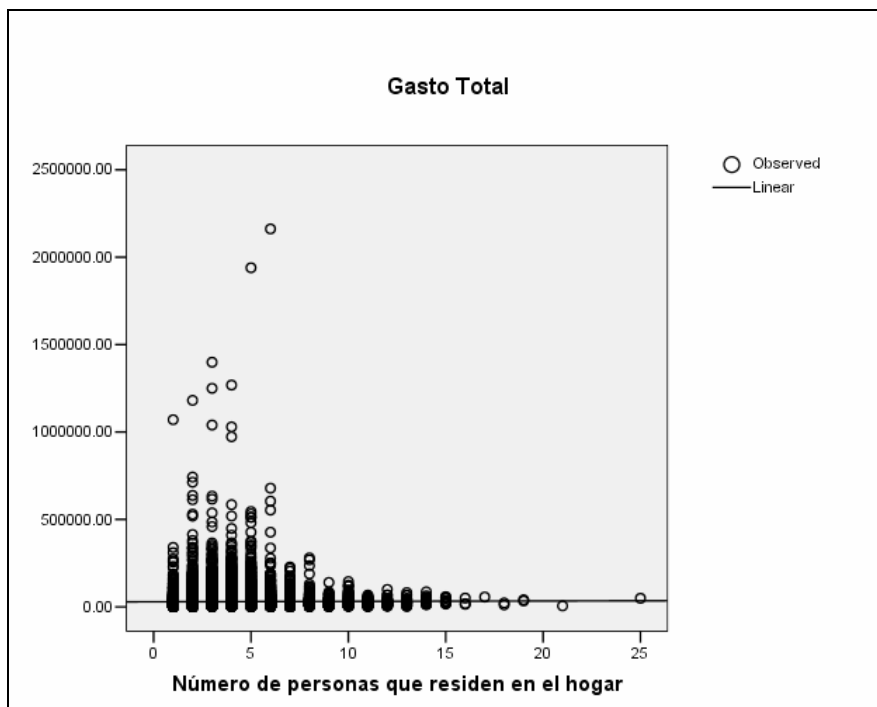


Gráfico 5: Ajuste de Curvas Número de Personas que residen en el Hogar - Gasto



6. Múltiples causas. Al igual que en el caso de las interacciones, es imposible afirmar en aspectos sociales que existen causas únicas. Todo es producto de una conjugación de distintos factores. Sin embargo, dado el carácter estructural del ingreso para determinar el gasto, es evidente que en el caso de esta relación entre variables, existe una causa que es predominante y que explica una parte importante de la varianza. De esta manera, un R^2 de 0,65 es un valor alto para una relación en ciencias sociales, donde siempre se asume que la realidad tiene múltiples causas. Sin embargo, no es un valor suficientemente grande, para afirmar que es determinante. Según este criterio, el nivel de complejidad es medio (1).

Analizando estos distintos aspectos queda en evidencia que el modelo tiene un nivel de complejidad medio (5 de 12).

c. Comparación 3: Regresión Lineal comparado Con Redes Neuronales Artificiales – Relación Entre Variables De Complejidad Media


❖ Base de datos

Al igual que para la relación entre variables simple del Modelo Causal, se utiliza la Encuesta Nacional de Ingresos y Gastos de Hogares mexicana del 2005.

❖ Descripción del modelo según Regresión Lineal Simple

Se utilizan las mismas variables que para los modelos causales, sólo que en este caso se analiza solamente la capacidad predictiva que tiene la variable ingreso sobre la variable gasto.

De esta manera, el modelo planteado es el siguiente:



Las variables incluidas son:

- **Gasto Total Hogar:** Incluye todos los gastos realizados por el hogar en un período determinado. De esta manera, se contabilizan los gastos en alimentos, vestuario, electricidad, entre otros. A su vez, se le suma autoconsumo, pago en especies, regalos y erogaciones financieras y de capital.
- **Ingreso Total Hogar:** incluye todos los ingresos que el hogar obtiene en un período determinado. Incluye ingresos, autoconsumo, pago en especie, regalos, estimación del alquiler e ingresos no monetarios.

El modelo afirma que el gasto total del hogar es predicho por el ingreso total del hogar.

❖ **Descripción del Modelos según Redes Neuronales Artificiales.**

Para el caso de las RNA, se incorporan las mismas variables. Ingreso Total del Hogar es la variable de input, mientras que el Gasto es el output que se busca predecir.

❖ **Evaluación de los datos según el Instrumento de Diagnóstico de la Complejidad de relaciones entre variables**

Dado que en el apartado anterior se analizó la complejidad de esta relación, no se vuelve a discutir, sino que se asume que esta es de 5 de 12, es decir, de complejidad media.

d. Comparación 4: Modelo Causal Recursivo comparado con Modelo Causal No Recursivo – Relación entre Variables de Complejidad Alta

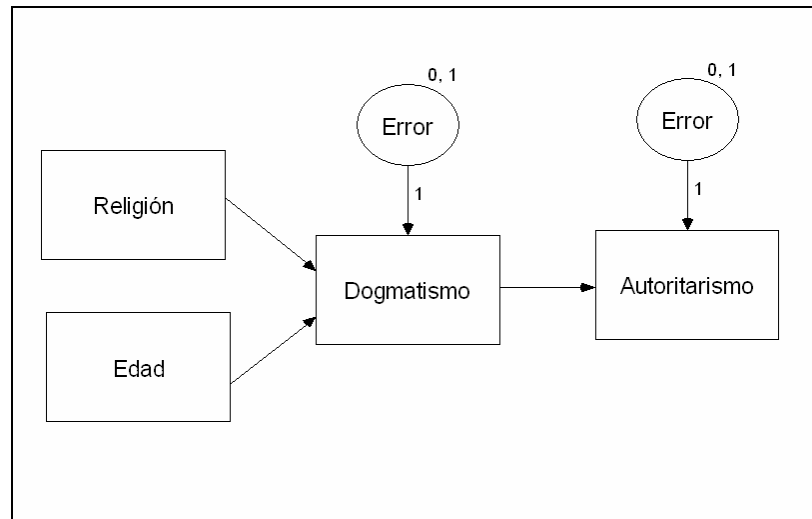
❖ Base de datos

Para este análisis se utiliza la base de datos de la Encuesta Tolerancia y No-Discriminación del Departamento de Sociología de la Universidad de Chile⁴. Esta base de datos cuenta con información de 1398 encuestados de Santiago, Temuco e Iquique.

❖ Descripción del modelo según un Modelo Causal no recursivo.

El modelo no recursivo propuesto es el siguiente (ver Gráfico 6):

Gráfico 6: Modelo Causal No Recursivo – Comparación 4



⁴ Estudio realizado por Manuel Vivanco, Manuel Canales y Jaime Aymerich

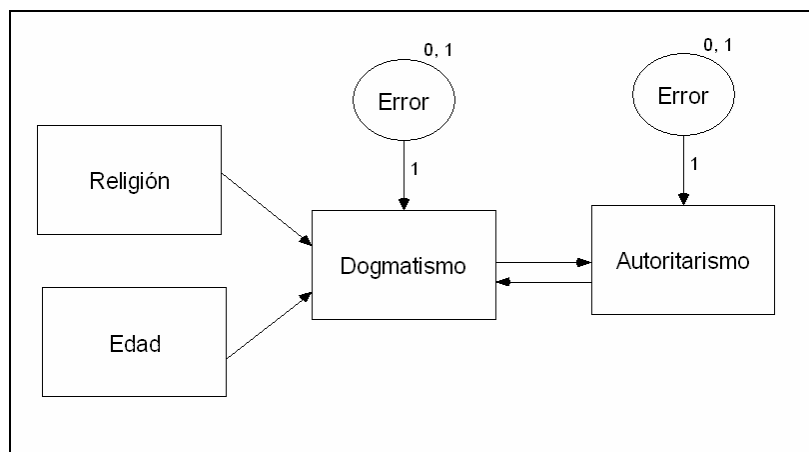
Las variables incluidas son:

- **Autoritarismo:** Este es un índice construido en base a afirmaciones de tipo Likert, en las cuales se pregunta el grado de acuerdo o desacuerdo con respecto a conductas, valores y actitudes autoritarias. La escala va de 1 a 6.
- **Dogmatismo:** Este es un índice construido en base a afirmaciones de tipo Likert, en las cuales se pregunta el grado de acuerdo o desacuerdo con respecto a conductas, valores y actitudes dogmáticas. La escala va de 1 a 6.
- **Religión:** Se refiere a si el encuestado tiene una religión (1) o no (0).
- **Edad:** Se refiere a la edad del encuestado.

El modelo afirma que la edad y el tener o no religión influyen en una actitud dogmática. A su vez, esta influye en una conducta autoritaria. Este es un modelo muy simplificado, sin embargo, sirve para los propósitos de este estudio.

❖ Descripción del Modelos según un Modelo Causal recursivo.

Este mismo modelo puede ser expresado de manera recursiva de la siguiente manera (ver Gráfico 7):

Gráfico 7: Modelo Causal Recursivo – Comparación 4

Según este modelo, el dogmatismo influye en el autoritarismo, mientras que el autoritarismo también influye en el dogmatismo. De esta manera, se genera una retroalimentación entre ambas variables. Esta relación puede ser argumentada en el sentido de que, por un lado, una actitud autoritaria requiere de una base dogmática de comprensión de la realidad y, a su vez, que una actitud autoritaria genera un aún mayor dogmatismo.

❖ **Evaluación de los datos según el Instrumento de Diagnóstico de la Complejidad de relaciones entre variables.**

A continuación se evalúa este modelo según los distintos criterios definidos anteriormente, de manera de poder demostrar que se trata de un modelo complejo.

- 1. Recursividad.** Como planteado anteriormente, este modelo es recursivo, dado que dogmatismo influye en autoritarismo, mientras que autoritarismo influye en dogmatismo. De esta manera, según este criterio, el nivel de complejidad es alto (2).
- 2. Errores de medición y Ruido.** Este modelo cumple con los dos aspectos planteados. Por un lado, corresponde a información recogida por medio de encuestas y no por medio de observaciones directas. De esta manera, la probabilidad de errores de medición y ruido es mayor. A su vez, autoritarismo y dogmatismo son conceptos complejos, tanto en el sentido de su construcción como en la dificultad que presenta para los encuestados responder a preguntas de esta índole. Otro posible ruido es el hecho de que los indicadores se calculan en base a ítemes. Sin embargo, si alguno de los ítemes falta, el indicador se calcula como un promedio de los restantes. De esta manera, los puntajes en los índices no corresponden siempre a los mismos ítemes. De esta manera, según este criterio, el nivel de complejidad es alto (2).
- 3. Datos perdidos.** Como se planteó recién, dado que los indicadores se construyen como promedios, es posible calcular los mismos aún con muchos datos perdidos. De esta manera, no existen datos perdidos en los índices, sin embargo, las variables que componen estos índices tienen todas datos perdidos, llegando hasta a un 6% de los mismos. De esta manera, el nivel de complejidad según este criterio es alto (2).
- 4. Interacciones.** Todos los aspectos culturales y valóricos interaccionan con una serie de factores. Sin ir más lejos, la actitud dogmática puede interactuar con otros aspectos culturales, con el nivel socioeconómico, con la religión, entre otros. En el modelo mismo, por ejemplo, sería posible afirmar que edad

y religión pueden interactuar generando un efecto conjunto en dogmatismo. De esta manera, es posible encontrar un número significativo de interacciones en este modelo. Según este criterio, el nivel de complejidad es alto (2).

5. Linealidad. Si bien autoritarismo y dogmatismo se relacionan de manera lineal, con un R^2 de 0,47 (ver Gráfico 8), la relación con las otras variables no es lineal. De esta manera, ni la edad, ni la religión se relacionan de manera lineal con dogmatismo, explicando, en el primer caso, un 6% de la varianza y en el segundo, un 7% (ver Gráficos 9 y 10). De esta manera, el modelo incluye importantes relaciones no lineales. Según este criterio, el nivel de complejidad es alto (2).

Gráfico 8: Ajuste de Curvas Autoritarismo - Dogmatismo

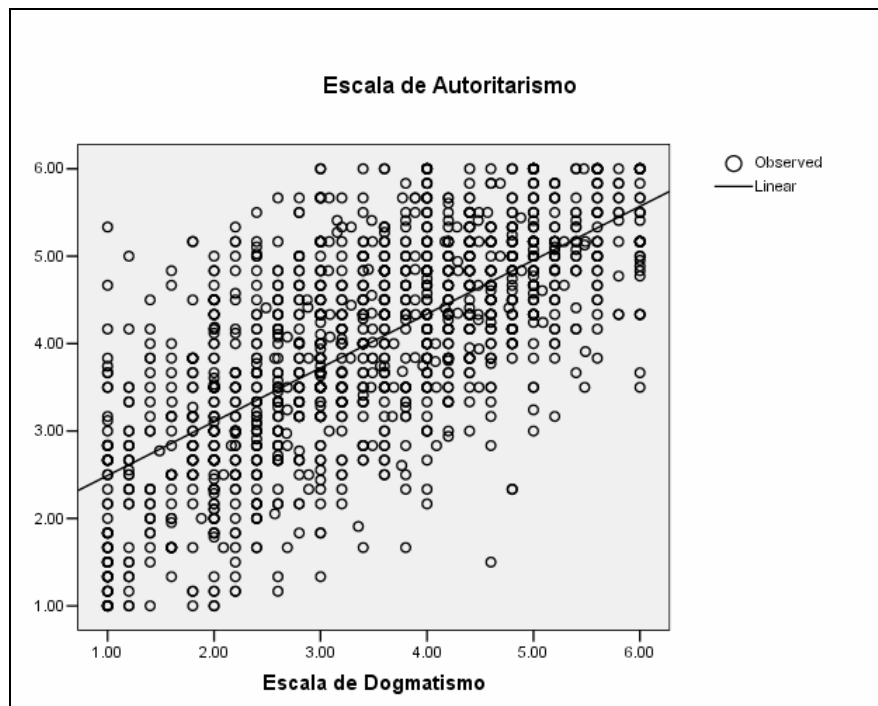


Gráfico 9: Ajuste de Curvas Dogmatismo - Edad

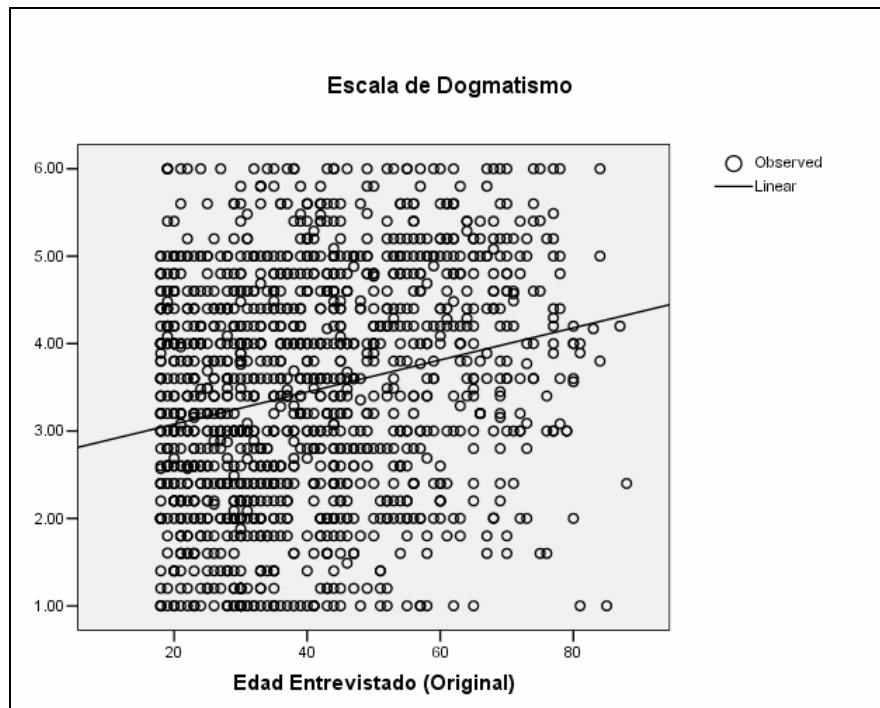
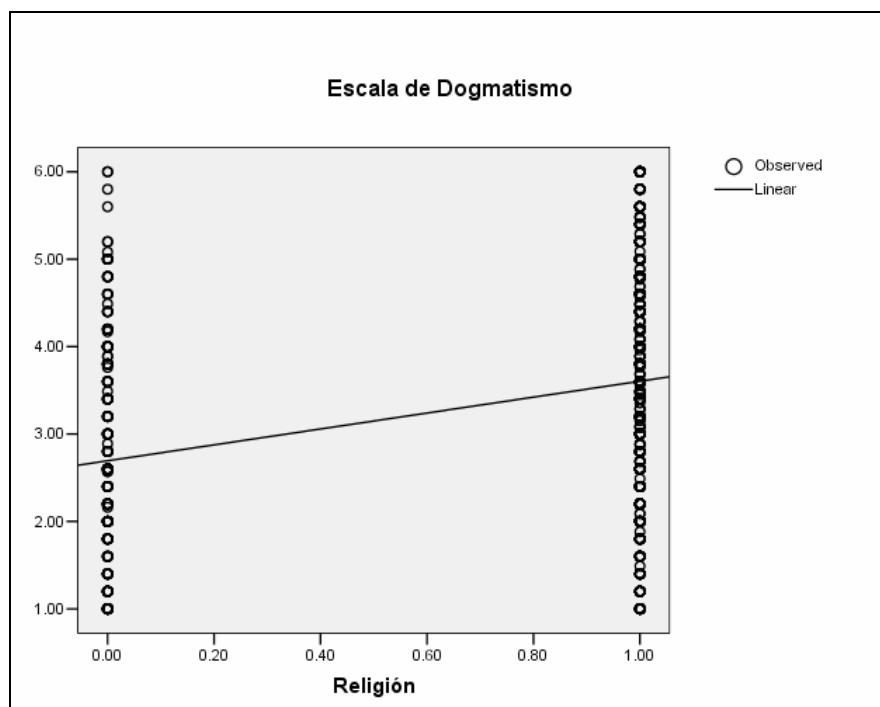


Gráfico 10: Ajuste de Curvas Dogmatismo - Religión



6. Múltiples causas. Los aspectos valóricos presentan una multiplicidad de causas. Desde aspectos educacionales y culturales, hasta aspectos de calidad de vida y económicos. De esta manera, es posible entender como la edad y la religión explican solamente un 6 y un 7%, respectivamente, del dogmatismo. Si bien el dogmatismo explica un 47% de autoritarismo, es evidente que en este modelo faltan una multitud de causas. Según este criterio, el nivel de complejidad es alto (2).

Por lo tanto, es posible afirmar que el modelo propuesto presenta un nivel de complejidad alto (12 de 12 puntos).

e. Comparación 5: Regresión Lineal Múltiple comparada con Redes Neuronales Artificiales – Relación entre Variables de Complejidad Alta

❖ Base de datos

Para esta parte del análisis se parte de un modelo propuesto por Inglehart y Wenzel (2005). Los autores trabajan en el marco de la Encuesta Mundial de Valores y proponen un modelo para predecir los puntajes de distintos países en un eje de valores Tradicionales/Seculares para la próxima medición de la misma encuesta. Este modelo fue reconstruido en parte, utilizando datos de la Encuesta Mundial de Valores⁵, así como del CIA World Factbook⁶, sobre distintos países. La base de datos está compuesta por 63 países de los cuales se cuenta con información acerca de los valores Tradicionales/Seculares.

❖ Descripción del modelo según Regresión Lineal Múltiple

El modelo de Inglehart y Wenzel (2005) plantea que el valor Tradicional/Secular es un producto de aspectos económicos y culturales. Entre estos aspectos distinguen:

- a. El GNP per cápita de cada país
- b. El porcentaje de fuerza de trabajo dedicado al sector secundario y terciario
- c. El número de años que el país vivió en un régimen comunista
- d. Un factor zonal cultural

Para reconstruir lo mejor posible este modelo, se buscaron datos de las distintas variables en distintas fuentes. Finalmente se pudieron reconstruir todas, a excepción del número de años que el país vivió en un régimen comunista, dado que esto implicaba un análisis histórico más detenido y complicado.

⁵ <http://www.worldvaluessurvey.org>

⁶ <https://www.cia.gov/cia/publications/factbook/index.html>

Las variables que finalmente se utilizaron fueron:

- **GDP per cápita:** Producto global bruto, dividido por el total poblacional. Corresponde al valor final de bienes y servicios producidos en un país en un año determinado. En este caso, al no contar con la información del GNP por país, se utiliza el GDP. Esta información se obtuvo del CIA Factbook.
- **Porcentaje de fuerza de trabajo dedicada al sector secundario y terciario:** Corresponde al porcentaje de fuerza laboral según la ocupación de la misma. En este caso, se excluye el porcentaje dedicado al sector primario. Esta información se obtuvo del CIA Factbook.
- **Factor zonal cultural:** Es un factor calculado por Inglehart y Wenzel (2005) asumiendo diferencias de herencia cultural de distintos países. De esta manera, calculan un factor que incluye tanto aspectos culturales como religiosos para distintas zonas. Por ejemplo, presentan un factor para la Europa Protestante, otro para la Europa Católica y otro para países de habla inglesa. Esta información fue utilizada para clasificar los 232 países según esta definición y adjuntarles el factor correspondiente.

La relación entre estas variables para el Modelo de Regresión Múltiple es la siguiente:

GDP per cap+ % sector secundario y terciario + Factor → Valor Tradicional/Secular

❖ **Descripción del Modelos según Redes Neuronales Artificiales.**

Para las RNA se utilizan las mismas variables, sólo que asumidas de la siguiente manera:

GDP per cap	:	Input
% sector secundario y terciario	:	Input
Factor	:	Input
Valor tradicional/secular	:	Output

De esta manera, se busca predecir el output por medio de la introducción de los distintos inputs.

❖ **Evaluación de los datos según el Instrumento de Diagnóstico de la Complejidad de relaciones entre variables**

A continuación se evalúa este modelo según los distintos criterios definidos anteriormente, de manera de poder demostrar que se trata de un modelo complejo.

- 1. Recursividad.** Es posible afirmar que este modelo es recursivo. De esta manera, existen factores económicos y culturales que influyen en el aspecto valórico Tradicional/Secular, sin embargo, es posible plantear que este último también influye en los aspectos económicos y culturales anteriormente planteados. Esto es afirmado desde estudios tan antiguos como los de Weber. De esta manera, según este criterio, el nivel de complejidad es alto (2).
- 2. Errores de medición y Ruido.** Este modelo cumple con los dos aspectos planteados. Por un lado, corresponde a información recogida por medio de encuestas y no por medio de observaciones directas. De esta manera, la probabilidad de errores de medición y ruido es mayor. A su vez, el valor Tradicional/Secular es un constructo complejo, tanto en el sentido de su construcción como en la dificultad que presenta para los encuestados responder a preguntas de esta índole. Según este criterio, el nivel de complejidad es alto (2).

- 3. Datos perdidos.** Las bases de datos de países tienden a tener muchos datos faltantes, dado que no en todos los lugares la sistematización de información funciona de la misma manera. En este caso ocurre lo mismo. De hecho, solamente se obtuvo la información sobre el valor Tradicional/Secular de los países para los cuales la Encuesta Mundial de Valores tenía información de estudios anteriores. Por esta razón, se tuvo que eliminar del análisis a más de la mitad de los países. Con respecto a los países que finalmente quedaron en el análisis, un 7.9% no tiene datos del porcentaje de fuerza de trabajo por sectores. Las otras variables tienen datos completos. Según este criterio, el nivel de complejidad es alto (2).
- 4. Interacciones.** En este modelo es posible encontrar un sin fin de interacciones. Sin ir más lejos, el GDP interacciona con el porcentaje de fuerza laboral por sectores. A su vez, existen muchas variables que pueden interaccionar con las variables del modelo, como es el caso de otras variables culturales, religiosas o económicas. Según este criterio, el nivel de complejidad es alto (2).
- 5. Linealidad.** Las relaciones en el modelo no son fuertemente lineales. La relación entre GDP per capita y valor Tradicional/Secular (ver Gráfico 11), si bien tiene una tendencia a comportarse de manera lineal, no sigue exactamente una línea, explicando el primero solamente un 20% del segundo. Lo mismo ocurre con el Porcentaje de Fuerza Laboral en el sector secundario y terciario (ver Gráfico 12), la cual explica un 18% del valor tradicional/secular. Por último, en el caso de la relación entre el Factor zonal cultural, la relación es un poco más lineal (ver Gráfico 13), explicando el 52% del valor Tradicional/Secular. Según este criterio, el nivel de complejidad es alto (2).

Gráfico 11: Ajuste de Curvas Valor Tradicional/Secular – GDP per cápita

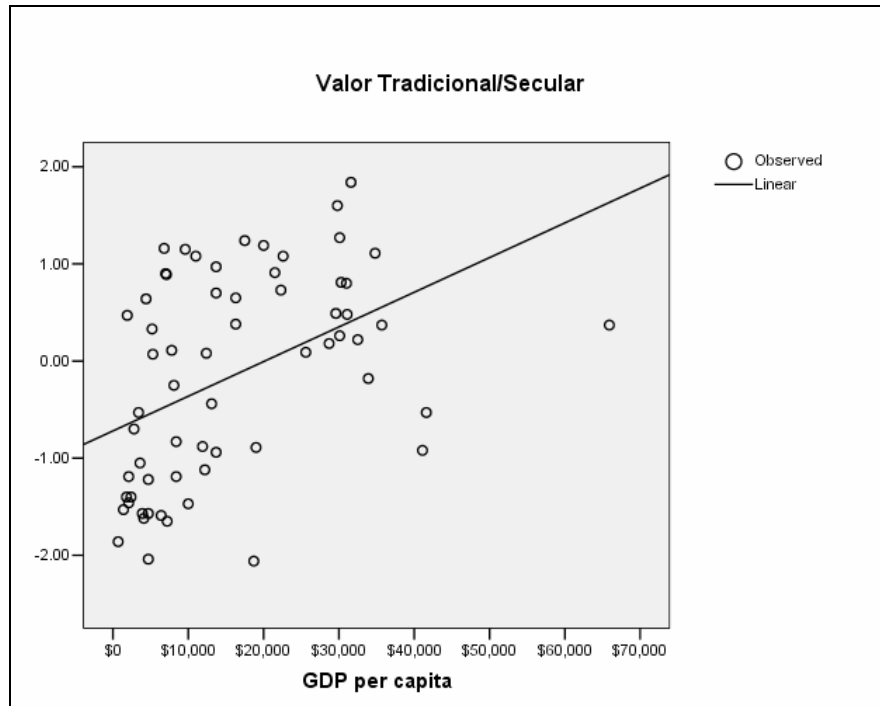
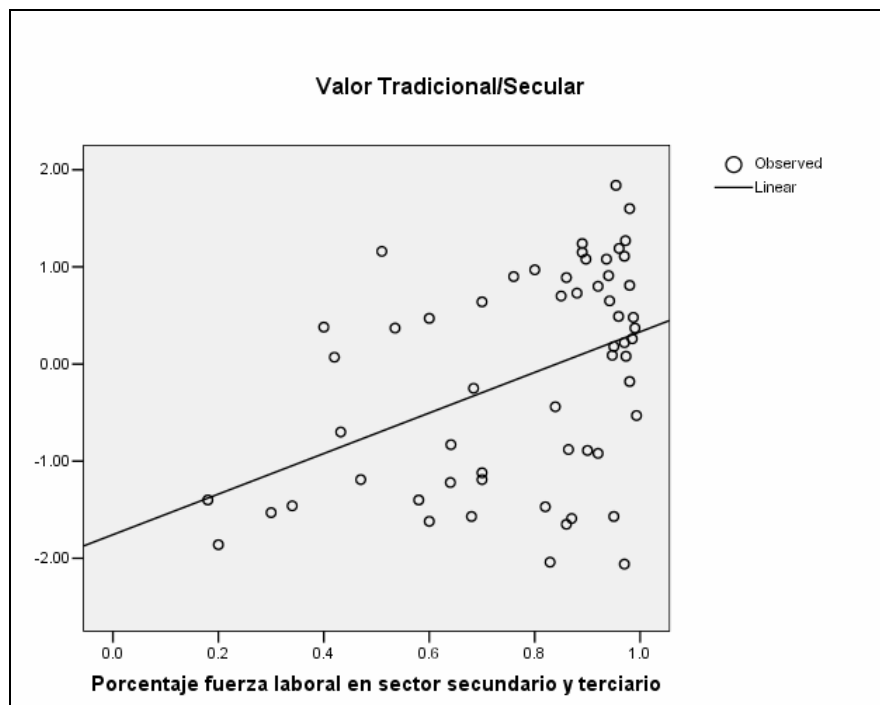
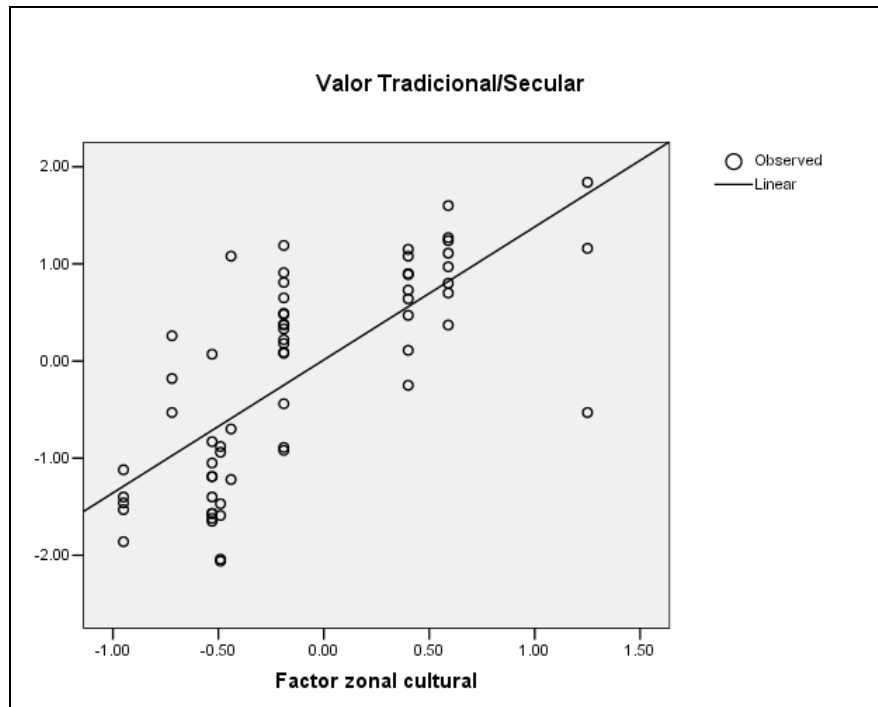


Gráfico 12: Ajuste de Curvas Valor Tradicional/Secular – Porcentaje de fuerza laboral en sector secundario y terciario



**Gráfico 13: Ajuste de Curvas Valor Tradicional/Secular –
Factor zonal cultural**



6. **Múltiples causas.** Evidentemente el valor Tradicional/Secular tiene una serie de causas. Esto se puede afirmar ya desde la observación del modelo propuesto. Su predicción se busca realizar en base a cuatro variables (en el modelo original) y no se logra explicar el total de su varianza. Ya partiendo del supuesto de que debe ser explicado tanto por factores económicos y culturales, es posible afirmar que no es un fenómeno simple. Según este criterio, el nivel de complejidad es alto (2).

Analizando estos distintos aspectos queda en evidencia que el modelo presentado presenta una serie de aspectos que lo hacen ser altamente complejo (12 de 12 puntos).

8. Diseño de las Técnicas de Análisis de Datos

a. Modelos Causales Recursivos y No Recursivos

Los modelos causales recursivos y no recursivos se diseñan exactamente igual, con la única diferencia de la inclusión de una relación recursiva en el primer caso.

Para el análisis de modelos causales se utiliza el programa estadístico AMOS 5.0.1. Los modelos son definidos por medio del dibujo del diagrama de secuencia entre las distintas variables. Las relaciones son determinadas por medio de flechas. El método de estimación seleccionado es el de Máxima Verosimilitud. Esta decisión se toma, dado que este método permite el trabajo con modelos recursivos y no recursivos. Se definió un nivel de confianza del 95% para todas las estimaciones de efectos entre variables. Se establece que en el caso de valores perdidos, estos fueran estimados por medio de promedios.

Los criterios de comparación de los modelos son los siguientes:

- **GFI (Goodness of Fit)**. Es un coeficiente que mide la bondad de ajuste del modelo. Su valor superior es 1, lo que implica un ajuste perfecto.
- **R²**. Es el coeficiente de determinación. Es un estimador del porcentaje de varianza de la variable dependiente que es explicada por el modelo.

En el caso del Modelo recursivo, se analiza también el índice de estabilidad, el cual permite afirmar si el modelo fue capaz de encontrar una solución estable al problema. Valores superiores a 1 en este índice indican inestabilidad y, por lo tanto, que el modelo es incorrecto.

No se analiza el valor del Chi Cuadrado, dado a que este estadístico tiende a encontrar diferencias explicativas muy fácilmente cuando las muestras son grandes.

b. Regresión Lineal Simple y Múltiple

El diseño es igual para los dos modelos de regresión lineal, ya sea los que son simples o múltiples (para relaciones entre variables simple y compleja).

Para este análisis se utiliza el programa estadístico SPSS v.13. El método de inclusión de variables seleccionado es "Enter", el cuál ingresa todas las variables simultáneamente, sin eliminar variables que no discriminen lo suficiente. De esta manera, es posible comparar modelos con las mismas variables. Se optó por la eliminación de los casos que tengan alguna variable perdida. Esto se hizo simplemente porque las otras opciones (eliminación de casos según análisis; y reemplazo por la media) producían peores resultados. Se define un nivel de confianza del 95% para las estimaciones.

Se utiliza el valor del coeficiente de correlación múltiple (R^2) para evaluar la capacidad predictiva del modelo.

c. Redes Neuronales Artificiales

El diseño de las RNA es igual para los dos modelos (relaciones simples y complejas).

Se utiliza el programa Neuro Shell v.2. Se toman las siguientes decisiones:

- **Entrenamiento.** Se define que se utilice el 40% de la base de datos para la fase de entrenamiento. Este porcentaje es seleccionado al azar, de manera de asegurar que se cubran todos los escenarios posibles y la fase de entrenamiento pueda ser generalizada. La tasa de aprendizaje se deja en el valor predeterminado (0.1 para el caso de una variable input y 0.3 para el caso de 3 variables input). Se testeó modificar esta tasa, sin lograr cambios significativos en la red. El criterio para detener el entrenamiento es un análisis de si el error baja de manera significativa o se mantiene igual por un lapso largo de tiempo. Se determina que se guarde el set de entrenamiento con los mejores resultados.

- **Arquitectura.** Se opta por una Red Ward. Esta red utiliza varias capas ocultas y un sistema de retropropagación (Backpropagation). Las capas ocultas tienen funciones de activación diferentes, lo que les permite distinguir distintas características en los patrones ingresados a la red. Esto permite que la capa de salida pueda ver los datos de varias maneras distintas. Entre las distintas arquitecturas Ward se selecciona el uso de tantas capas ocultas como variables input (1 en el caso del modelo simple y 3 en el caso del modelo complejo). En el caso del modelo complejo, el incorporar 3 capas ocultas permite ingresar tres funciones de activación distintas, permitiendo obtener tres distintas maneras de analizar los datos. Se opta por esta arquitectura ya que se recomienda para la obtención de predicciones. Además, de manera experimental, se comparó con los resultados de otras arquitecturas, obteniendo mejores resultados.

Se utiliza el valor del coeficiente de correlación múltiple (R^2) para evaluar la capacidad predictiva del modelo.

9. Hipótesis

Las hipótesis se plantean recién en este punto, debido a que implican la operacionalización de varios temas. De esta manera, serán más entendibles luego de haber hecho todas las aclaraciones necesarias.

La hipótesis general es:

- A mayor complejidad de la relación entre variables, mayor será el rendimiento de las técnicas con características complejas.

Esta hipótesis se desagrega en términos del análisis en las siguientes cinco:

1. La Regresión Lineal y las Redes Neuronales Artificiales tienen un rendimiento similar cuando la relación entre variables es de un nivel de complejidad bajo.

2. Los Modelos Causales Recursivos tienen un rendimiento superior a los Modelos Causales No Recursivos cuando la relación entre variables tiene una complejidad media.
3. Las Redes Neuronales Artificiales tienen un rendimiento superior a la Regresión Lineal cuando la relación entre variables es de un nivel de complejidad medio.
4. Los Modelos Causales Recursivos tienen un rendimiento superior a los Modelos Causales No Recursivos, cuando la relación entre variables es de un nivel de complejidad alto.
5. Las Redes Neuronales tienen un rendimiento superior a la Regresión Lineal, cuando la relación entre variables es de un nivel de complejidad alto.

A su vez, de manera comparativa se establece que:

- A medida que aumenta el nivel de complejidad de la relación entre variables, el rendimiento superior de las técnicas con características complejas se vuelve mayor.

Esta hipótesis se desagrega en términos operativos en las dos siguientes:

1. A medida que aumenta el nivel de complejidad de la relación entre variables, el rendimiento superior de los Modelos Causales Recursivos sobre los Modelos Causales no recursivos se vuelve mayor.
2. A medida que aumenta el nivel de complejidad de la relación entre variables, el rendimiento superior de las Redes Neuronales Artificiales por sobre la Regresión Lineal se vuelve mayor.

VI. Resultados

A continuación se presentan los resultados para cada una de las comparaciones realizadas. En cada caso, se contrastan los resultados obtenidos en los criterios estadísticos definidos.

a. Comparación 1: Regresión Lineal comparada con Redes Neuronales Artificiales – Relación entre Variables de Complejidad Baja

En el caso de la Regresión Lineal, se ingresó la variable Voltaje como variable independiente y la variable Corriente como variable dependiente. Esto mismo se hizo en el caso de las RNA.

Los resultados obtenidos son los siguientes (ver Tabla 3):

Tabla 3: Resultados Comparación 1

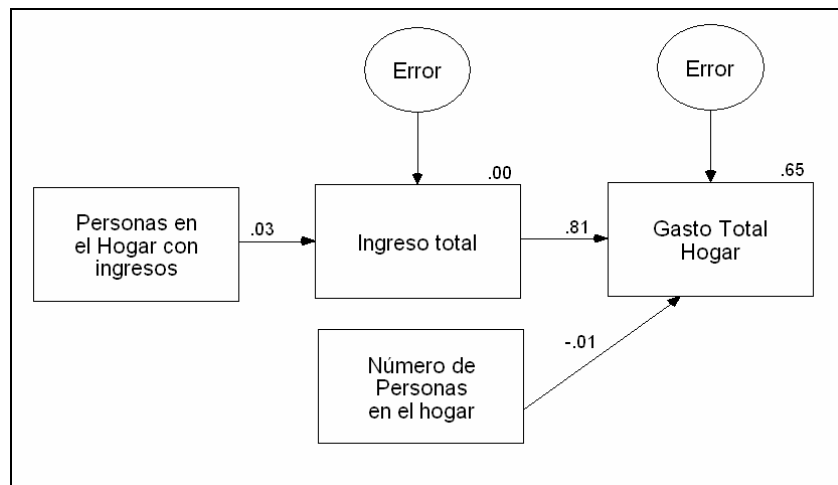
	REGRESIÓN LINEAL	RNA
R² Corriente	99,99%	99,95%

En ambos casos el porcentaje de varianza explicado es altísimo. De hecho, es prácticamente del 100%. A su vez, ambas técnicas tienen un rendimiento casi igual.

b. Comparación 2: Modelo Causal Recursivo comparado con Modelo Causal No Recursivo – Relación entre Variables de Complejidad Media

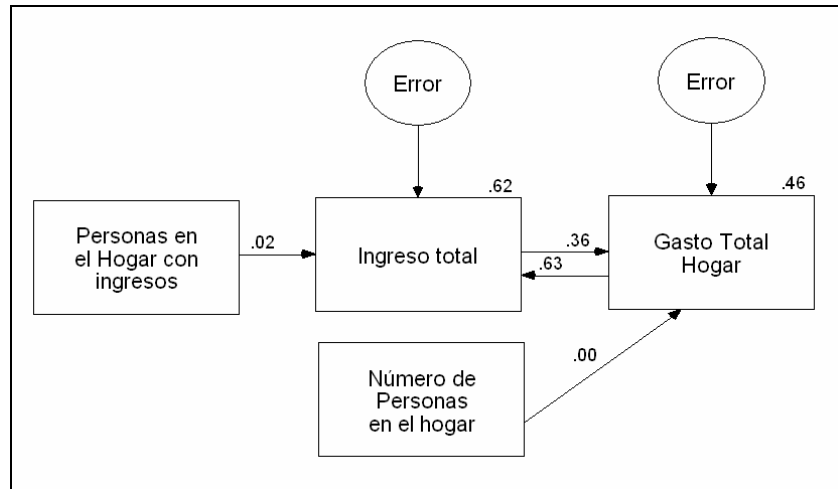
El modelo no recursivo se encuentra sobreidentificado, obteniendo 3 grados de libertad. De esta manera, es posible encontrar una solución. Los resultados estandarizados obtenidos en el caso del modelo no recursivo son los siguientes (ver Gráfico 14):

Gráfico 14: Modelo Causal No Recursivo – Comparación 2



Según esto, el Gasto Total del Hogar es explicado en un 65% por las variables del modelo. A su vez, el Ingreso Total del Hogar no es explicado por el modelo. Se observa que el número de personas en el hogar no es un buen predictor para el gasto total del hogar, así como el número de personas en el hogar con ingresos no es un buen predictor del ingreso total. El GFI (Goodness of Fit) es de 0,85, valor bastante cercano a 1 como para afirmar que ajusta bien a los datos.

A su vez, el modelo recursivo obtuvo 2 grados de libertad, por lo que también se encuentra sobreidentificado. Los resultados estandarizados son los siguientes (ver Gráfico 15):

Gráfico 15: Modelo Causal Recursivo – Comparación 2

La inclusión de una relación recursiva entre gasto e ingreso, lo único que logró fue “llevar” la varianza explicada desde gasto a ingreso. De esta manera, la varianza explicada de gasto disminuyó de un 65% a un 46%, si bien la varianza explicada de ingreso aumentó de 0% a un 62%. Sin embargo, queda claro que esto es un mero resultado de una correlación entre ambas variables, no es que el gasto sea predictor del ingreso. El GFI del modelo es el mismo que el del modelo no recursivo (0,85). El modelo es estable, obteniendo un índice de 0,23, inferior al límite de 1.

En la Tabla 4 se comparan los resultados de ambos modelos:

Tabla 4: Resultados Comparación 2

	MODELO CAUSAL NO RECURSIVO	MODELO CAUSAL RECURSIVO
R² Gasto Total Hogar	65%	46%
R² Ingreso Total Hogar	0%	62%
GFI	0.85	0.85
Índice de estabilidad	-	0.23

Se puede concluir que la incorporación de una relación recursiva en el segundo modelo no logró mejorar su rendimiento. Si bien aumentó “ficticiamente” la varianza explicada de la variable ingreso, no logró aumentar la varianza explicada de la variable que realmente se buscaba explicar. De hecho, el GFI quedó exactamente

igual, por lo que se puede afirmar que la complejización del modelo, por medio de la inclusión de la relación recursiva, no tuvo un efecto positivo.

c. Comparación 3: Regresión Lineal comparada con Redes Neuronales Artificiales – Relación entre Variables de Complejidad Media

En el caso de la Regresión Lineal, se ingresó la variable Ingreso como variable independiente y la variable Gasto como variable dependiente. Esto mismo se hizo en el caso de las RNA.

Los resultados obtenidos son los siguientes (ver Tabla 5):

Tabla 5: Resultados Comparación 3

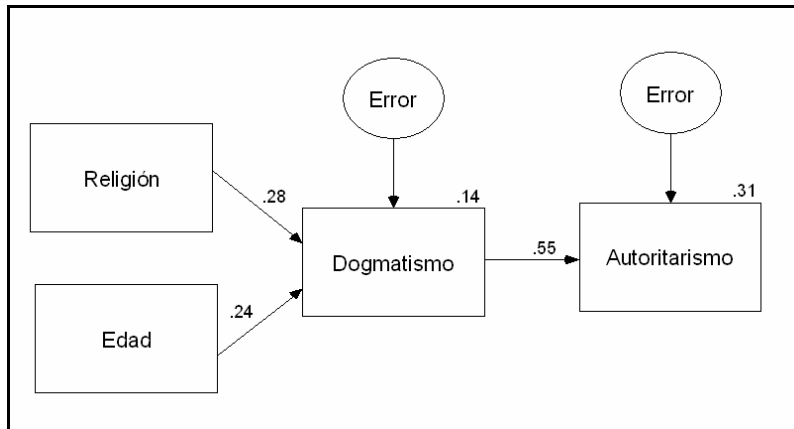
	REGRESIÓN LINEAL	RNA
R² Gasto Total Hogar	65,4%	87,3%

Las RNA obtuvieron un porcentaje de varianza explicado significativamente superior al de la regresión lineal. La mejora de las RNA con respecto a la regresión es del 21,9%.

d. Comparación 4: Modelo Causal Recursivo comparado con Modelo Causal No Recursivo – Relación entre Variables de Complejidad Alta

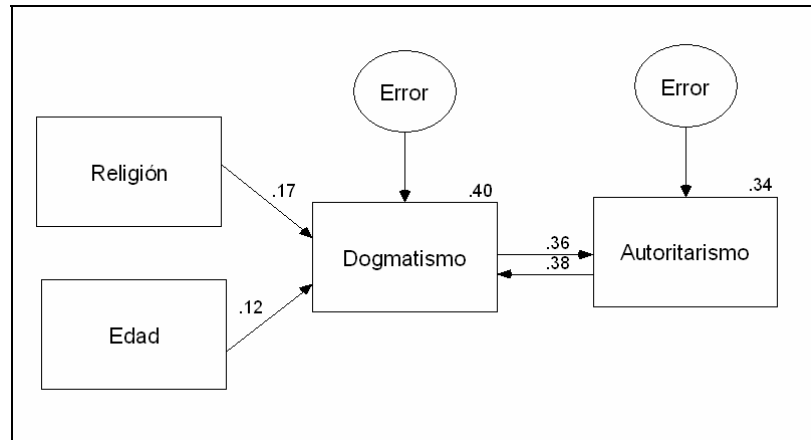
El modelo no recursivo se encuentra sobreidentificado, obteniendo 5 grados de libertad. De esta manera, es posible encontrar una solución. Los resultados estandarizados obtenidos en el caso del modelo no recursivo son los siguientes (ver Gráfico 16):

Gráfico 16: Modelo Causal No Recursivo – Comparación 4



Según esto, el Autoritarismo es explicado en un 31% por el modelo. A su vez, el Dogmatismo es explicado en un 14%. El GFI (Goodness of Fit) es de 0,91, valor bastante cercano a 1 como para afirmar que ajusta bien a los datos.

A su vez, el modelo recursivo obtuvo 4 grados de libertad, por lo que también se encuentra sobreidentificado. Los resultados estandarizados son los siguientes (ver Gráfico 17):

Gráfico 17: Modelo Causal Recursivo – Comparación 4

Para empezar, este modelo es totalmente estable. Su índice de estabilidad es 0.14, mucho inferior al tope de 1. A su vez, se observa que el modelo, al incluir una relación recursiva, aumenta la proporción de varianza explicada, tanto para el Autoritarismo (alcanzando un 34%) como para el Dogmatismo (alcanzando un 40%). A su vez, el GFI aumenta a 0,96, implicando un mejor ajuste del modelo a los datos. Por lo tanto, el modelo recursivo logra mejores resultados que el no recursivo. Sin embargo, es necesario destacar que la mejora en la predicción de la variable dependiente no es especialmente grande.

A continuación se presenta una tabla comparando los resultados de ambos modelos (ver Tabla 6):

Tabla 6: Resultados Comparación 5

	MODELO CAUSAL NO RECURSIVO	MODELO CAUSAL RECURSIVO
R² Autoritarismo	31%	34%
R² Dogmatismo	14%	40%
GFI	0.91	0.96
Índice de estabilidad	-	0.139

Por lo tanto, el modelo recursivo, que es más complejo que el no recursivo, logra mejorar la predicción y ajuste del modelo, tanto en términos de varianza explicada como de ajuste del GFI. Si bien la varianza explicada de Autoritarismo solamente aumenta en un 3%, la varianza explicada de Dogmatismo aumenta en 26%. Esto

indica que ambas variables se retroalimentan mutuamente, generando en conjunto un mejor modelo.

e. Comparación 5: Regresión Lineal Múltiple comparada con Redes Neuronales Artificiales – Relación entre Variables de Complejidad Alta

En el caso de la Regresión Lineal, se ingresaron las variables GDP per capita, Porcentaje de fuerza laboral en sectores secundarios y terciarios y el factor zonal cultural como variables independientes y la variable Valor Tradicional/Secular como dependiente. Esto mismo se hizo en el caso de las RNA, ingresando las primeras como input y las segundas como output.

Los resultados obtenidos son los siguientes (ver Tabla 7):

Tabla 7: Resultados Comparación 6

	REGRESIÓN LINEAL	RNA
R² Valor Tradicional/Secular	68%	99,1%

Las RNA obtuvieron un porcentaje de varianza explicada muy superior al de la regresión lineal. Este valor es superior en un 31.1%.

f. Comparación de las diferencias

A continuación se presenta un cuadro resumen de los resultados (ver Tabla 8):

Tabla 8: Diferencia entre Modelos, para distintos niveles de Complejidad

	MODELO CAUSAL RECURSIVO – MODELO CAUSAL NO RECURSIVO			REGRESIÓN LINEAL – REDES NEURONALES ARTIFICIALES	
	Diferencia R ²	Diferencia GFI	R	Diferencia R ²	R
Baja Complejidad	-	-	-	0%	=
Mediana Complejidad	-9% y +62%	0	=	+21.9%	+
Alta Complejidad	+3% y 26%	+0.05	+	+31.1%	+

En el caso de los Modelos Causales, en el análisis de mediana complejidad, la incorporación de una relación recursiva no logra mejorar el modelo. De hecho, empeora el porcentaje de varianza explicada de la variable dependiente en un 3%, dado que reordena la varianza hacia la variable independiente. Sin embargo, este reordenamiento se debe simplemente a la correlación entre ambas variables, no a un efecto temporal-causal. En términos del GFI se puede constatar que ambos modelos son similares. Con respecto a esto último, es posible afirmar que la introducción de un aspecto complejo en una relación que no tiene tal característica (la recursividad), no ayuda a mejorar la predicción.

A su vez, en el caso de alta complejidad, el modelo logra mejorar la predicción de la variable dependiente en un 3%, así como la de la variable independiente en un 26%. De esta manera, en el caso de los Modelos Causales, es posible constatar que en el caso de la alta complejidad, el uso de la técnica con características complejas permite un rendimiento superior al de la mediana complejidad. A su vez, es posible

concluir que a medida que aumenta el nivel de complejidad, el rendimiento del Modelo causal recursivo por sobre el no recursivo aumenta.

En el caso de la comparación entre Regresión Lineal y RNA, en la relación de baja complejidad ambas técnicas son iguales. Sin embargo, en la de mediana y alta complejidad, las RNA tienen un rendimiento superior. A su vez, este rendimiento es mayor en el caso de la relación de alta complejidad que en el de la mediana complejidad.

VII. Discusión

Tal vez la primera conclusión a la que se puede llegar con respecto a esta investigación tiene que ver con la dificultad de encontrar relaciones entre variables de baja complejidad. De hecho, relaciones entre variables complejas existen muchas. Concluir con respecto a cuáles podían ser utilizadas para esta investigación no tuvo mayores complicaciones. Para encontrar la relación de baja complejidad, se buscó primeramente en bases de datos de economía. En este contexto, la relación entre ingreso y gasto parecía ser lo más simple y determinista que se podía encontrar en temas sociales. Sin embargo, aplicando el instrumento de diagnóstico, se evidenció que esta relación no era para nada simple y que su nivel de complejidad era medio. Por lo tanto, hubo que seguir buscando una relación más simple, la cuál fue encontrada finalmente en la física. El largo proceso de búsqueda de esta relación, y el haberla encontrado solamente en ámbitos alejados a las ciencias sociales, indica que efectivamente la realidad social tiene poco de simple. De hecho, todas las bases de datos revisadas, cumplían por lo menos algunos de los criterios de mediana y alta complejidad. Es más, tampoco entre datos de física y química, ciencias clásicas que son asumidas como más simples que las sociales, fue fácil encontrar una relación lineal y determinista.

Con respecto a las comparaciones realizadas, se puede afirmar que el uso de técnicas con características complejas, a medida que la relación entre variables se vuelve más compleja, presentan una capacidad predictiva cada vez mayor, en relación a las técnicas de análisis estadístico clásico. Esto se evidenció especialmente

en el caso de las Redes Neuronales Artificiales, donde, en el caso de la relación de baja complejidad los resultados eran similares, mientras que en la relación de mediana complejidad permitían una predicción superior en un 21,9%, y en la de alta complejidad, superior en un 31.3%. Sin embargo, por medio del análisis de los Modelos Causales se llegó a una conclusión un poco distinta. En el caso de la relación de alta complejidad, el Modelo Causal Recursivo efectivamente logró un mejor rendimiento que el Modelo Causal No Recursivo, pero esto no ocurrió en el caso de la relación de mediana complejidad. La conclusión que se puede sacar de esto tiene que ver con que aumentar la complejidad de la técnica en un aspecto en el cual la relación entre variables no es compleja, no aporta una mejora en la capacidad predictiva. Es más, hasta puede empeorarla. Por lo tanto, si bien la relación entre ingreso y gasto es de mediana complejidad, y por medio de las RNA se logró obtener un mejor resultado, la introducción de la relación recursiva -no existente en la realidad- no puede más que perturbar el modelo.

Por otro lado, es posible comparar los resultados obtenidos para los Modelos Causales Recursivos con los de las Redes Neuronales. Los Modelos Causales Recursivos, como se dijo en un principio, corresponden a la estadística clásica, si bien presentan algunas características más complejas que la estadística convencional. Sin embargo, las Redes Neuronales son un tipo de procesamiento que se ajusta, prácticamente en todas sus características, a la complejidad. Por lo tanto, se puede afirmar que las Redes Neuronales son más complejas que los Modelos Causales Recursivos. Esto se observó también en los resultados. Los Modelos Causales Recursivos, en el caso de la relación de alta complejidad, lograron mejorar los resultados, sin embargo, esta mejora fue solamente marginal. En cambio, las Redes Neuronales lograron mejoras muy significativas.

A manera de conclusión, es posible afirmar que a medida que las relaciones entre variables aumentan su complejidad, las técnicas con características complejas se vuelven cada vez más útiles. De hecho, en el caso de relaciones de alta complejidad, es totalmente recomendable utilizar Redes Neuronales en vez de Regresión Lineal. Sin embargo, utilizar técnicas más complejas de lo que requieren los datos no es recomendable por dos razones. Primero, porque no logrará mejorar el rendimiento o hasta lo entorpecerá y, segundo, porque implica utilizar una técnica que es de un

acceso más difícil para los científicos sociales, tanto en términos de software como de manejo de técnicas alternativas.

VIII. Conclusiones

La presente investigación ha analizado la teoría y el método de la complejidad. Se ha discutido la posibilidad de que la complejidad efectivamente se constituya en un paradigma. Con respecto a esto último, se ha afirmado que si bien aún no es posible hablar de un paradigma de la Complejidad como tal, existe una base común a partir de la cual sería posible que se constituyera uno. Para que esto ocurriera, sin embargo, son necesarias principalmente dos cosas.

Para empezar, los teóricos de la complejidad debieran intentar unificar sus esfuerzos por avanzar en el área. Tal vez el mayor obstáculo de esto tiene que ver con la gran variedad de áreas desde las cuales se conversa sobre complejidad y la falta de un lenguaje común. En este contexto, el Instituto de Santa Fe ha dado un importante paso adelante en la unificación de distintas ciencias en torno a la complejidad.

A su vez, es necesario avanzar en la constitución de un método de la complejidad. Morin (2005) ha avanzado en la constitución de un método, el pensamiento complejo. Sin embargo, hace falta avanzar en técnicas concretas para abordar la complejidad, especialmente en términos de análisis de datos. En esta investigación se han explorado algunas posibilidades asociadas a los Modelos Causales Recursivos y a las Redes Neuronales Artificiales. Especialmente la última, ha mostrado ser muy capaz para trabajar con relaciones entre variables de alta complejidad. Sin embargo, es necesario avanzar en esta línea de manera de poder determinar definitivamente el método de la complejidad, el cuál debiera ser aceptado por todos los teóricos de la complejidad.

La importancia de la constitución de un paradigma de la complejidad tiene que ver especialmente con la necesidad de constituir una ciencia que permita abordar las temáticas sociales. Como lo han demostrado muchos autores y como se ha planteado también en esta investigación, la realidad social se encuentra llena de

relaciones no lineales, de desorden, de causalidades complejas, entre otros. De hecho, ni siquiera la física es hoy capaz de afirmar que la realidad es simple. Sin embargo, a pesar de esta situación, muchas de las teorías y técnicas utilizadas en las ciencias sociales siguen siendo una copia de la de la ciencia clásica. Es más, en muchos casos, la imitación de las ciencias naturales es un intento por hacer avanzar a las disciplinas por el camino "correcto". Sin embargo, las técnicas estadísticas convencionales implican una suma de supuestos que no se pueden cumplir en las ciencias sociales. Tal vez el más importante de estos es la linealidad. Si bien existen técnicas que no requieren que la relación sea lineal, es posible observar un uso indiscriminado de técnicas lineales en problemas no lineales. La Regresión Lineal, como prototipo de investigación, es tal vez la técnica favorita de muchos científicos sociales, los cuales la aplican sin revisar si se cumplen los supuestos de linealidad. Esto se puede deber a la facilidad con la que hoy en día se pueden analizar datos por medio de programas estadísticos. Se introduce una base de datos y se corre para ver si existe una relación entre las variables, sin parar a analizar si efectivamente la técnica utilizada sirve para los datos utilizados. Al aplicar esta técnica es posible concluir que dos variables no se encuentran relacionadas, solamente por no obtener un coeficiente de regresión alto. Sin embargo, es posible que exista una fuerte relación, solo que esta no sea lineal.

Esta situación lleva a una conclusión ineludible: los métodos que utilizamos no pueden ser independientes de la realidad que se observa, sino que deben ser ad hoc a la misma. Esto es válido no solamente para ámbitos complejos, sino también para ámbitos de baja complejidad. De esta manera, utilizar técnicas altamente complejas, como las Redes Neuronales, para relaciones simples, no tiene ningún sentido. Lo único que se va a lograr es complicar innecesariamente el análisis de los datos. Sin embargo, es igualmente absurdo utilizar una técnica como la Regresión Lineal, la cual está diseñada para estudiar ciertos tipos de datos, en relaciones altamente complejas y no lineales. No es posible pedirle a las técnicas cosas para las cuales no fueron diseñadas. También en términos teóricos es posible afirmar que no es posible "importar" una teoría y ajustarla a la fuerza a la realidad que se observa. En este sentido, eliminar el desorden, el azar, las fluctuaciones y las no linealidades de lo social, solo para que ajuste a teorías clásicas, es un absurdo. Teoría y técnica deben ser construidas para trabajar con la realidad.

Esta situación tiene dos conclusiones fundamentales.

Primero, es inevitable un análisis previo de la realidad que se quiere estudiar para determinar el método que se debe utilizar para estudiarla. En esta investigación se ha propuesto un instrumento de diagnóstico de la complejidad de las relaciones entre variables, el cuál permite explorar los datos y así determinar su nivel de complejidad antes de seleccionar la técnica apropiada. Esto es relevante, dado que se han observado importantes diferencias en el rendimiento de las técnicas según el nivel de complejidad de las relaciones que se analizan. Sin embargo, es necesario proseguir con los esfuerzos en este sentido, de manera de poder constituir instrumentos de diagnóstico de los datos (linealidad, complejidad, entre otros) que se constituyan en requisitos –y no posibilidades asociadas en los programas computacionales- de diagnóstico antes de utilizar una técnica.

Segundo, que es necesario tomar en cuenta los aspectos característicos de la realidad que se quiere estudiar, para así definir teorías que se ajusten a los datos y no ajustar los datos a la teoría. En este sentido, cabe plantear que la complejidad se ajusta a las ciencias sociales, dado que permite incorporar y no excluir los temas propiamente sociales como lo son el juego entre orden, desorden, azar, fluctuaciones y organización.

IX. Bibliografía

- ❖ Arnold, M., Sánchez, A., García A., Opazo, J.E. y Osorio, F. (1991): Introducción a los conceptos básicos de la teoría general de sistemas. Universidad de Chile, Facultad de Ciencias Sociales, Departamento de Antropología. Programa de Investigación Spitze.
- ❖ Asher, H. (1984). Causal Modeling. Estados Unidos: Sage Publications.
- ❖ Balandier, G. (1996). El desorden. La teoría del caos y las ciencias sociales. Elogio de la fecundidad del movimiento. Barcelona, España: Gedisa Editorial.
- ❖ Berry, W. (1984): Nonrecursive causal models. Estados Unidos: SAGE Publications.
- ❖ Briggs, J. y Peat, F.D. (2001). Espejo y Reflejo: Del caos al orden. Guía ilustrada de la teoría del caos y la ciencia de la totalidad. Barcelona: Editorial Gedisa.
- ❖ Buckley, W. (1967): La sociología y la teoría moderna de los sistemas. Buenos Aires: Amorrortu Editores.
- ❖ Byrne, B. (2001). Structural Equation Modeling with AMOS. New Jersey: Lawrence Erlbaum Associates Publishers.
- ❖ Byrne, D. (1998). Complexity Theory and the Social Sciences. Nueva Cork: Routledge.
- ❖ Capra, F. (2003a). La trama de la vida. Una nueva perspectiva de los sistemas vivos. Barcelona: Editorial Anagrama.
- ❖ Capra, F. (2003b). Las conexiones ocultas. Implicaciones sociales, medioambientales, económicas y biológicas de una nueva visión del mundo. Barcelona: Anagrama.

- ❖ Kenny, D. (1979). *Correlation and Causality*. Nueva York: John Wiley & Sons.
- ❖ García, R. (1979). *Crítica de la Teoría de Sistemas*. Madrid: Centro de Investigaciones Sociológicas.
- ❖ Garson, D. (1998). *Neural Networks. An Introduction Guide for Social Scientists*. Londres: SAGE Publications.
- ❖ Cowan, J. y Sharp, D. (1999). *Redes Neuronales e Inteligencia Artificial*. En: Graubard, S. (1999). *El nuevo debate sobre la inteligencia artificial. Sistemas simbólicos y redes neuronales*. Barcelona: Gedisa Editorial.
- ❖ Hair, J., Anderson, R., Tatham, R. y Black, W. (1999): *Análisis Multivariante*. Madrid: Prentice Hall.
- ❖ Hayles, K. (2000). *La Evolución del Caos. El orden dentro del desorden en las ciencias contemporáneas*. Barcelona: Editorial Gedisa.
- ❖ Hinton, G. (1992): *Redes Neuronales que aprenden de la experiencia*. *Investigación y Ciencia*, Nr. 194, pp. 105-112.
- ❖ Inglehart, R. y Wenzel, C. (2005). *Exploring the Unknown: Predicting the Responses of Publics not yet Surveyed*. Extraído el 24 de noviembre de 2006 de <http://www.worldvaluessurvey.org>
- ❖ Johansen, O. (1994). *Introducción a la teoría general de sistemas*. México D.F.: Limusa Noriega Editores.
- ❖ Kline, R. (1998). *Principles and practice of structural equation modelling*. Nueva York: The Guilford Press.
- ❖ Kuhn, T.S. (2000). *La estructura de las revoluciones científicas*. Chile: Fondo de Cultura Económica.

- ❖ Lamo de Espinosa, E., Gonzáles, J.M. y Torres, C. (1994). La sociología del conocimiento y de la ciencia. España: Alianza Editorial.
- ❖ Lasky, L. (2002): Sobre el tiempo... En: Pérez-Taylor, R. Editor (2002): Antropología y complejidad. Barcelona: Editorial Gedisa S.A.
- ❖ Leiva, M., Rioja, J. y Veneros, R. (2002). Aplicación de Redes Neuronales Artificiales para la predicción del comportamiento de precios del commodity amoníaco. Memoria para optar al título de Magíster en Administración con mención en Finanzas. Universidad de Chile, Facultad de Ciencias Económicas y Administrativas, Escuela de Graduación.
- ❖ Lewin, R. (2002): Complejidad. El caos como generador del orden. Barcelona: Tusquets Editores.
- ❖ Martín, B. y Sanz, A. (1997). Redes Neuronales y Sistemas Borrosos. Madrid: Ra-Ma Editorial.
- ❖ Martínez, M. (1997). El paradigma emergente. Hacia una nueva teoría de la racionalidad científica. México D.F.: Trillas.
- ❖ Maturana, H. y Varela, F. (2004). De máquinas y seres vivos. Autopoiesis: La organización de lo vivo. Buenos Aires: Editorial Universitaria.
- ❖ Maturana, H. y Varela, F. (1990). El árbol del conocimiento. Santiago de Chile: Editorial Universitaria.
- ❖ Mier, R. (2002). Complejidad: bosquejos para una antropología de la inestabilidad. En: Pérez-Taylor, R. Editor (2002). Antropología y complejidad. Barcelona: Editorial Gedisa S.A.
- ❖ Montañó, J.J. y Palmer, A. (2002). Redes Neuronales artificiales: abriendo la caja negra. En: Metodología de las Ciencias del Comportamiento 4(1), pp. 77-93. Aemcco.

- ❖ Montaña, J.J. (2002). Redes Neuronales Artificiales aplicadas al Análisis de Datos. Tesis Doctoral. Universitat de Les Illes Balears. Facultat de Psicologia. Palma de Mallorca.
- ❖ Morin, E. (2001). El Método I. La naturaleza de la naturaleza. Madrid: Ediciones Cátedra.
- ❖ Morin, E. (1983). El Método II. La vida de la vida. Madrid: Ediciones Cátedra.
- ❖ Morin, E. (1988). El Método III. El conocimiento del conocimiento. Madrid: Ediciones Cátedra.
- ❖ Morin, E. (1984). Ciencia con Consciencia. Barcelona: Anthropos.
- ❖ Morin, E. (2005). Introducción al pensamiento complejo. Barcelona: Gedisa Editorial.
- ❖ Nicolis, G. y Prigogine, I. (1997). La estructura de lo complejo. En el camino hacia una nueva comprensión de las ciencias. Madrid: Alianza Editorial.
- ❖ Pérez, A.R. (1999). Kuhn y el cambio científico. México: Fondo de Cultura Económica.
- ❖ Pérez, M. y Martín, Q. (2003). Aplicaciones de las Redes Neuronales Artificiales a la Estadística. Cuadernos de Estadística. Madrid: Editorial La Muralla.
- ❖ Pérez-Taylor, R. (2002). Introducción. Algunas reflexiones para pensar-comprender una antropología de la complejidad. En: Pérez-Taylor, R. Editor (2002). Antropología y complejidad. Barcelona: Editorial Gedisa S.A.
- ❖ Prigogine, I. y Stengers, I. (1990). La nueva Alianza. Madrid: Alianza Editores.
- ❖ Prigogine, I. (2004). ¿Tan sólo una ilusión? Barcelona: Tusquets Editores.

- ❖ Prigogine, I. (1997a). El fin de las certidumbres. Santiago de Chile: Editorial Andrés Bello.
- ❖ Prigogine, I. (1997b). Las leyes del caos. Barcelona: Crítica.
- ❖ Rodríguez, D. y Arnold, M. (1999). Sociedad y Teoría de Sistemas. Santiago de Chile: Editorial Universitaria.
- ❖ Roger, E. (2001). Una Antropología Compleja para entrar en el Siglo XXI. Claves de Comprensión. Extraído el 5 de mayo 2006, de <http://www.complejidad.org/13-antcomp.htm>
- ❖ Situngkir, H. (2003): Emerging the Emergence Sociology. The Philosophical Framework of Agent- Based Social Studies. Department of Computational Sociology. Bandung Fe Institute. Research University on Complexity in Indonesia. *Journal of Social Complexity* 1.
- ❖ Villanueva, J.C. (2006): Sobre la complejidad en torno a Edgar Morin. Extraído el 10 de mayo del 2006 de http://www.nonopp.com/ar/filos_educ/00/Morin_complejidad.htm
- ❖ Von Bertalanffy, L. (1995). Teoría General de los Sistemas. México D.F.: Fondo de Cultura Económica.
- ❖ Waldrop, M. (1992). Complexity. The emerging science at the edge of order and chaos. Nueva York: Simon & Schuster Paperbacks.
- ❖ Wiener, N. (1969). Cibernética y Sociedad. Buenos Aires: Editorial Sudamericana.
- ❖ Zúñiga, M. J. (2003). Una vuelta de tuerca a propósito de la complejidad. Estudio iniciativo sobre caos. Memoria para optar al título de socióloga. Universidad de Chile, Facultad de Ciencias Sociales, Departamento de Sociología.