

UNIVERSIDAD NACIONAL DE INGENIERIA
FACULTAD DE INGENIERIA INDUSTRIAL Y DE SISTEMAS
SECCION DE POSGRADO



Modelaje y Análisis Comparativo de la Situación Productiva y
Competitiva del Sector Industrial Manufacturero mediante la aplicación
de Redes Neuronales y Estadísticas Multivariadas

TESIS

Para Optar el Grado Académico de
MAESTRO EN CIENCIAS
CON MENCION EN INGENIERIA DE SISTEMAS

RENZO JOSE FIGUEROA PALOMINO

LIMA - PERU

2007

INDICE

	Pág.
RESUMEN	2
INTRODUCCION	3
PLANTEAMIENTO METODOLOGICO	9
CAPITULO I: GENERALIDADES DE LAS REDES NEURONALES ARTIFICIALES Y EL MODELO DE SISTEMAS	24
1.1. Redes Neuronales Artificiales	24
1.1.1 Fundamentos Biológicos	26
1.1.2 Modelo General de una Red Neuronal Artificial	27
1.1.3 Arquitectura	32
1.1.4 Método de aprendizaje	34
1.2. Modelo de Perceptrón Multicapa - MPL	35
1.2.1. La regla delta generalizada	36
1.2.1.1. Funcionamiento del algoritmo	37
1.2.1.2. Adición de un momento en la regla delta generalizada	37
1.2.2. Estructura y aprendizaje por retropropagación de errores	39
1.2.2.1. Algoritmo de entrenamiento	39
1.2.3. Consideraciones del algoritmo de aprendizaje	42
1.2.3.1. Control de convergencia	43
1.2.3.2. Dimensionamiento de la red	44
1.2.3.3. Inicialización y cambio de pesos	45
1.2.4. Deducción de la regla backpropagation	46
1.2.5. Análisis de sensibilidad	49

1.3. Modelo del Sistema de Competitividad en la clasificación de los Subsectores Industriales	50
1.3.1. Nivel de investigación	50
1.3.2. Necesidades del sistema	51
1.3.3. Selección del modelo de RNA	51
1.3.4. Fuentes de recolección de datos	52
1.3.5. Selección de variables relevantes	53
1.3.6. Modelo del Sistema de Competitividad del Sector Industrial Manufacturero	53
1.3.6.1. Aplicación de la metodología de sistemas suaves	53
1.3.6.2. Sistema de competitividad del sector industrial Manufacturero	60
CAPITULO II: DESARROLLO DEL PROCESO DE CLASIFICACION DE LAS ACTIVIDADES INDUSTRIALES MANUFACTURERAS	62
2.1. Planteamiento del problema	63
2.2. Requerimiento del sistema	63
2.3. Datos disponibles y criterio de selección de variables	64
2.4. Elección del modelo	73
2.5. Elección de los conjuntos de aprendizaje y test	76
2.6. Preprocesamiento	76
2.7. Proceso de entrenamiento	78
2.8. Evaluación de resultados	78
CAPITULO III: ANALISIS Y PROCESAMIENTO DE LA DATA MEDIANTE EL SOFTWARE DE NEURAL SOLUTION	85
3.1. Proceso de entrenamiento de la data	85
3.2. Validación cruzada y test de la data	86
3.3. Modelación de la data mediante el perceptrón multicapa	86
3.4. Número de capas ocultas	86
3.5. Nivel de salida	87
3.6. Aprendizaje supervisado	87

3.7. Configuración de prueba	88
3.8. Modelo gráfico del perceptrón multicapa	88
CAPITULO IV: COMPARACION DE LAS TECNICAS DE REDES NEURONALES Y ESTADISTICAS	90
4.1. Redes neuronales y Estadística	90
4.2. Relaciones entre técnicas neuronales y estadísticas	91
4.3. Aplicación de las técnicas estadísticas	92
4.4. Análisis comparativo de resultados: técnicas de redes neuronales y estadísticas multivariadas	100
CONCLUSIONES Y RECOMENDACIONES	104
BIBLIOGRAFIA	109
ANEXOS	113

RESUMEN

El sector industrial exportador de los países, coexisten diferentes agentes económicos, política de liberalización y apertura. Para examinar los determinantes de la situación productiva y competitiva de la industria manufacturera se ha modelado y realizado un análisis comparativo de dos técnicas: redes neuronales y estadísticas multivariadas, a fin de evaluar la eficiencia del modelo de RNA frente a la estadística, a través de los indicadores de clasificación y minimización de errores.

Las dos técnicas mencionadas se aplicaron independientemente para la obtención del índice de competitividad de los 73 subsectores industriales en el año 2000. A partir de estos índices se categorizó y determinó las industrias según nivel de competitividad que presenta. El modelo empleado por las RNAs se basó en un perceptrón multicapa supervisado (con una capa oculta). En tanto que las técnicas estadísticas utilizaron el análisis multivariado (factorial y discriminante).

Existen diferencias en cuanto a los resultados obtenidos por ambas técnicas, 27 industrias fueron incorrectamente clasificadas como no competitivas con las estadísticas, cuando deberían serlo en base al resultado de RNAs. La diferencia radicaría en el peso generado para cada variable, las RNAs asignan mayor peso a las exportaciones; variable esencial en el modelo de competitividad, mientras que las estadísticas multivariadas lo asignan a la inversión fija.

La clasificación (%) correcta para las 73 manufacturas con el uso de las RNAs fue del 100% y una variabilidad en los datos de 0,2. Sin embargo, con las estadísticas multivariadas se clasificaron al 91,8% con 2,5 de variabilidad. De esto se concluye y reafirma a las RNAs como una herramienta potencial y eficiente en la clasificación de datos.

INTRODUCCION

En los últimos quince años, las redes neuronales artificiales (RNA) han emergido como una potente herramienta para el modelado estadístico orientada principalmente al reconocimiento de patrones, tanto en el análisis de clasificación como de predicción. Las RNA tienen una sólida base teórica y práctica que han demostrado ser herramienta útiles para procesar datos con ruido o incompletos, así como, la alta tolerancia a fallos que permite a la red operar satisfactoriamente con neuronas o conexiones dañadas y la capacidad de responder en tiempo real debido a su paralelismo inherente.

Actualmente, existen unos 40 paradigmas de RNA que son usados en diversos campos de aplicación (Taylor, 1996; Arbib, Erdi y Szentagothai, 1997; Sarle, 1998). Entre estos paradigmas, se destacan la red *backpropagation* (Rumelhart, Hinton y Williams, 1986) y los mapas autoorganizados de Kohonen (Kohonen, 1982).

Una red neuronal artificial es un modelo de computación inspirado en nuestros conocimientos sobre neurociencia, es decir, el estudio de las neuronas de nuestro sistema nervioso, aunque sin tratar de ser biológicamente realistas en detalle. En los últimos años estos modelos han experimentado un gran desarrollo gracias al descubrimiento de su excelente comportamiento en problemas de reconocimiento de patrones, predicción y clasificación, entre otros. Las redes neuronales artificiales son mecanismos matemáticos que aprenden a reconocer o clasificar patrones, tal como lo hace nuestro propio cerebro, dicho aprendizaje no descansa sobre un modelo preconcebido sino que busca las correlaciones existentes entre las variables del problema.

Los desarrollos más recientes de la inteligencia artificial han resaltado la importancia de los sistemas como soporte de ayuda a la toma de decisiones y de la información cualitativa, sugiriendo modelos desarrollados para asistir al decisor en la resolución de problemas. Por un lado, los sistemas expertos tratan de representar el conocimiento de forma simbólica, partiendo de la premisa de que los expertos humanos utilizan gran número de reglas heurísticas específicas en un determinado campo, las cuales son incorporadas al sistema. Por su parte, las redes neuronales artificiales tratan de representar el conocimiento de un modo conexionista y adaptativo, replicando la estructura neuronal del cerebro humano. Lo fundamental en este paradigma es el aprendizaje mediante patrones. La red *backpropagation* mediante un esquema de aprendizaje supervisado ha sido utilizada satisfactoriamente en la clasificación de patrones y en la estimación de funciones aplicados en diversos campos¹.

La aplicación de modelos de redes neuronales artificiales en la clasificación de datos y predicciones viene siendo una técnica de gran importancia en la industria. Debido a que se conoce que el sector industrial manufacturero contribuye de modo significativo en la generación de divisas para el país y que en estos últimos años varias actividades industriales con mayor valor agregado han perdido competitividad entre ellos: textiles, prendas de vestir, químicos, maquinarias y equipos, minerales no metálicos y muebles. Por ello, es importante aplicar este modelo para el análisis y evaluación de las actividades industriales que comprende el sector manufactura con respecto a su orientación al mercado interno y/o externo. Resultados que servirán con el propósito de aplicar medidas normativas, políticas y toma de decisiones sobre aquellas actividades que no presentan competitividad y en otras que necesitan reactivarse.

Dicha evaluación se basa en la categorización del nivel de competitividad que presentan las actividades industriales de la manufactura peruana mediante la obtención de un índice de competitividad calculado para cada subsector. Este

¹ La descripción de la Red de *Backpropagation* se encuentra en el documento desarrollado por Palmer, Montañó y Jiménez (1992), en prensa.

concepto de competitividad es incompatible con la dicotomía de mercado interno y externo, si las industrias son competitivas entonces lo son en ambos mercados. Tal es así que se incluyen variables relacionadas a la producción, comercio exterior e inversión extranjera.

La competitividad de la industria nacional no es una investigación reciente, uno de los estudios donde la tesis centra sus bases es el desarrollado por Jiménez Félix, Apolo G. y Kapsoli J. (1998) cuyo análisis se basa en “La Competitividad en la Industria Manufacturera Peruana” donde se examinan los determinantes de la competitividad de la industria manufacturera, mediante un modelo matemático que incluye como variables explicativas fundamentales; la productividad de mano de obra y el costo relativo del trabajo. Asimismo, presenta un indicador “ratio” de competitividad a nivel mundial, el cual se ha reformulado el indicador para un análisis a nivel local, utilizándose así en la tesis como referencia para conocer la situación competitiva del sector manufacturero en el periodo de análisis, ya que a partir de estos índices o ratios generados han permitido la construcción de un modelo neuronal de competitividad donde se emplea indicadores de comercio exterior, inversiones, producción y productividad para generar un nuevo indicador global de competitividad.

Asimismo, la tesis se basa en otro trabajo de investigación desarrollado por la Comisión Económica para América Latina (2000): “Análisis de la Competitividad del Sector Industrial Peruano - Metodología CAN PLUS”, donde se han generado indicadores para analizar el nivel de competitividad del sector industrial manufacturero peruano basándose únicamente en variables macroeconómicas de comercio exterior a fin de conocer la participación relativa del sector en el mercado internacional. Asimismo, han elaborado un software denominado CAN-PLUS que contiene información para 89 países y agrupaciones en el periodo 1977-1999 a un nivel de desagregación de a 3 dígitos del CIU. Este trabajo de investigación ha permitido en la tesis generar una matriz de competitividad que representa las posibilidades de dinamismo competitivo de un país definiéndose dos tipos de sectores: sectores dinámicos y sectores

estacionarios o estancados. Para ello, la metodología no solo se fundamenta en el estudio de variables de comercio exterior sino también incluye a otras variables de gran importancia como: producción, inversiones, materia prima y productividad, a fin de determinar la situación productiva y competitiva de los sectores mediante un análisis más detallado sin aludir los factores explicativos.

Otro estudio de investigación donde la tesis centra sus bases es el desarrollado por Saavedra Jaime (1996): “La Liberalización Comercial e Industria Manufacturera en el Perú”, en dicho estudio se evalúa de manera empírica el impacto de las reformas de comercio exterior sobre la estructura de la producción, el patrón de comercio exterior, capital extranjero y el empleo manufacturero, a fin de proporcionar los elementos indispensables sobre las posibilidades de sostener un crecimiento económico por largos periodos. Este estudio ha proveído a la tesis la identificación de los determinantes del desempeño de la industria manufacturera y de la economía peruana en los próximos años, permitiendo así la inclusión de indicadores macroeconómicos en la construcción de un modelo de competitividad del sector industrial manufacturero. Es necesario mencionar que el estudio de investigación no cuenta con una perspectiva sectorial (análisis de agregados macroeconómicos por nivel de actividad industrial - CIUs) por lo que el aporte de la presente tesis se efectúa a través de un análisis desagregado de las actividades industriales sobre la competitividad, la dinámica de inversiones y la productividad, con el propósito de determinar el papel de la manufactura peruana como generadora de crecimiento y desempeño de la misma en el sector externo.

Las técnicas matemáticas aplicadas en el estudio de clasificación de las actividades o ramas industriales con mayor competitividad en la industria peruana han sido desarrolladas con un modelo sencillo. Sin embargo, como una variante para el desarrollo del mismo, se ha empleado una metodología más explicativa y eficiente como es la técnica de las redes neuronales artificiales, ya que ésta tiene la capacidad de relacionar datos de entrada y salida del proceso, sin conocimiento anterior de la relación entre ambos, a través de sucesivos entrenamientos. Frente a

ello puede afirmarse que las redes neuronales artificiales tienen la habilidad de aprender con ejemplos o casos.

El estudio de investigación sobre el cual la presente tesis ha fundamentado la aplicación de la metodología de las redes neuronales ha sido desarrollado por Kapsoli Salinas, Javier y Bencich Aguila, Brigitt (2002): “Indicadores líderes, redes neuronales y predicción de corto plazo” donde muestra un procedimiento para construir un predictor de corto plazo del nivel de actividad económica (Producto Bruto Interno), basándose en modelos de redes neuronales que son esencialmente, modelos de indicadores, en los cuales no siempre hay clara una relación económica [Zhang, Guoqiang, B. Eddy Patuwo y Michael y Hu. 1994]. A pesar de ello, dado que lo que se busca es minimizar el error de predicción, los modelos que se presentan es una poderosa herramienta de análisis que tiene la finalidad de conocer el crecimiento económico de la economía peruana para los próximos años mediante la construcción de un modelo neuronal económico estimado y pronosticado a partir de un conjunto de variables líderes que adelantan al PBI. El enfoque de la tesis sobre el estudio de investigación mencionado ha centrado su análisis en generar un indicador de competitividad sectorial a partir de un conjunto de variables macroeconómicas vinculadas a las perspectivas del sector industrial manufacturero, permitiendo así clasificar las actividades económicas según su participación productiva y competitiva.

La presente tesis utiliza como herramienta de aplicación la técnica de las redes neuronales artificiales a fin de analizar la situación productiva y competitiva del sector industrial manufacturero, para ello emplea un modelo de retropropagación que permite realizar la clasificación de las actividades industriales, identificando así, a las actividades industriales de la manufactura peruana que han tenido un impacto positivo o negativo en su nivel de competitividad a partir del análisis de un conjunto de variables macroeconómicas en estudio relacionadas a la producción, inversión, productividad y comercio exterior; siendo evaluado en el período 2000 con información procesada de la Encuesta Anual del Sector Industrial Manufacturero, la cual es competencia del

Ministerio de la Producción como institución pública de fuente primaria. Asimismo, el análisis se centra en la determinación de la oferta exportable de las actividades industriales ya que resulta significativo identificar aquellos sectores que no han tenido una orientación exportable asociado a una posible orientación de su producción al mercado interno o que no produzca lo suficiente por falta de insumos u otros factores explicativos.

PLANTEAMIENTO METODOLOGICO

PLANTEAMIENTO DEL PROBLEMA

Para realizar el análisis de clasificación de las actividades industriales manufactureras (CIU)² aquellos que están orientados al mercado externo y de los que solo se dedican a la producción de bienes en el mercado local, existen muchas técnicas estadísticas, de las cuales, las que se han utilizado en estos últimos tiempos fueron las herramientas multivariadas y redes neuronales. Las herramientas multivariadas tienen mayor trascendencia en lo que se refiere a la investigación de mercados, mientras que la técnica con la que se han obtenido resultados satisfactorios han sido las redes neuronales. Partiendo de la metodología de las redes neuronales que es una herramienta que está emergiendo en los diferentes campos de investigación como: investigación de mercados, análisis financiero y macroeconómicos, farmacéuticos y consultaría de negocios. Se destaca por su mayor uso en los diversos campos del conocimiento: reconocimiento de patrones, predicción en series temporales, clasificación de datos, entre otros.

Como resultado de la formulación del problema se logrará obtener la eficiencia con la aplicación de la técnica de redes neuronales artificiales, permitiendo así la clasificación de datos en base al modelo hallado mediante esta técnica, el cuál posteriormente permitirá la clasificación de nuevos datos. La eficiencia de las redes neuronales está en que la técnica no requiere suposición sobre la forma de distribución de los datos, supuestos que muy pocas veces se cumplen.

² CIU: Clasificación Internacional Industrial Uniforme de las actividades económicas industriales publicada en 1958 después de ser examinada por la Comisión de Estadística de las Naciones Unidas.

Mediante la aplicación de esta metodología se pretende identificar y conocer el comportamiento de las actividades industriales (CIUs) que han orientado su producción al mercado externo, evaluando así su nivel de competitividad. Asimismo se identificará a las actividades industriales que no son competitivos, las cuales posiblemente se dedican a la producción de bienes y servicios con orientación al mercado local, siendo uno de los propósitos más importante de este estudio en identificar a las actividades que no presentan o han perdido competitividad, de tal forma que frente a ello las entidades competentes puedan evaluar, implementar y aplicar medidas normativas de liberalización sobre estas actividades económicas.

FORMULACION DEL PROBLEMA

¿Presenta la Industria Manufacturera una estructura competitiva externa? Y como un problema específico se plantea ¿Qué actividades económicas de la Industria Manufacturera orientan la mayor parte de su producción al mercado externo y/o interno?

HIPOTESIS

La Industria Manufacturera en el Perú en estos últimos años, en particular el año 2000 ha incrementado su competitividad, puesto que, a nivel desagregado (CIUs) las actividades económicas productoras con mayor valor agregado han orientado la mayor parte de su producción hacia el mercado externo, ello se vería reflejado por la apertura de mercados establecidos durante ese período.

OBJETIVOS

➤ OBJETIVO GENERAL

Evaluar y determinar el comportamiento de las Actividades Industriales de la Manufactura Peruana (CIUs) orientados al mercado externo, minimizando el porcentaje de error de clasificación mediante el modelo de redes neuronales.

➤ **OBJETIVOS ESPECIFICOS**

- Evaluar la eficiencia del modelo de redes neuronales en contraste con las técnicas estadísticas multivariadas minimizando el porcentaje de error de clasificación de las actividades industriales.
- Identificar las actividades industriales (CIIUs) con alta competitividad y aquellas que dedican su producción al mercado interno mediante la aplicación del modelo de redes neuronales.

JUSTIFICACION DE LA INVESTIGACION

El sector industrial exportador de los países, coexisten diferentes agentes económicos, política de liberalización y apertura, implementada en los años noventa, las cuales han tenido un impacto diferencial en los sectores productivos y al interior de los mismos, produciendo resultados más controvertidos en la industria manufacturera, más aún en la determinación de las actividades industriales que presentan una alta competitividad al interior del sector.

Asimismo, la perspectiva estratégica de la política económica estuvo basada en la competitividad como la más importante a inicios del año 2000. De tal forma que en los discursos políticos la aspiración esencial fue ganar competitividad en la economía mundial. En ese proceso se embarcó a la economía en su conjunto y a la industria en particular, donde las medidas estuvieron caracterizadas por su radicalidad y ortodoxia, al punto que el Perú se constituyó en ejemplo mundial de aplicación de las recetas del “Consenso de Washington”.

Frente a ello, el propósito de la investigación es analizar los resultados de ese proceso en el sector industrial, y esclarecer la polémica de la desindustrialización o reconversión industrial o ganancia de competitividad industrial. Es decir, nos preguntamos, si nuestra economía tuvo sus inicios de competitividad en el año 2000, y respecto a nuestra producción industrial, que niveles de competitividad ha logrado en ese periodo.

De esta forma, se emplea una nueva metodología de aplicación de modelos de redes neuronales artificiales en la clasificación de datos y predicciones, ya que a la fecha viene siendo una técnica de gran importancia en la generación de indicadores económicos para la economía peruana global y sectorial.

Por otro lado, es importante mencionar que el sector industrial manufacturero contribuye con el 36% de participación en la generación de divisas, representando así como el segundo sector productivo significativo en aliviar y reducir el déficit comercial creado por las actividades industriales netamente manufactureras: Textiles, Minerales no metálicos, Bebidas no alcohólicas y Vehículos automotores, las cuales presentan mayor valor agregado en la producción industrial manufacturera (Ver Anexo N°6), cuya participación es de 6,3%, 5,3%, 1,9% y 1,6%, respectivamente.

De esta manera, es importante emplear modelos de redes neuronales donde los resultados satisfactorios obtenidos servirán para el propósito de aplicar política y toma de decisiones sobre las actividades industriales que requieran una reactivación, protección, liberalización y nuevos mercados. Por ello, se realiza el análisis y evaluación de variables económicas para las diferentes actividades industriales del sector manufacturero donde la evaluación se basa en el análisis de la competitividad de las actividades industriales, determinando así su participación en el mercado interno y/o externo. El concepto de competitividad es incompatible con la dicotomía de mercado interno y externo, si las industrias son competitivas entonces lo son en ambos mercados. Tal es así que para conocer los factores explicativos del comportamiento del sector se incluyen variables relacionadas a la producción, comercio exterior, productividad e inversión.

Se han realizado diversos estudios sectoriales sobre la competitividad de la industria nacional, donde se examinan los determinantes de la competitividad de la industria manufacturera a través de un indicador de competitividad o un carente análisis descriptivo, el cual no cuenta con suficiente información adecuada para brindar un diagnóstico más desagregado del sector. Sin embargo, la presente tesis pretende desarrollar un modelo de competitividad mediante la

aplicación de las técnicas de redes neuronales artificiales, empleando para ello indicadores relacionados a la producción, productividad, comercio exterior e inversiones, los cuales permiten generar un indicador de competitividad; ya que el uso de este modelo presenta la capacidad de relacionar datos de entrada y salida del proceso, sin conocimiento anterior de la relación entre ambos, a través de sucesivos entrenamientos. Además, puede afirmarse que las redes neuronales artificiales tienen la habilidad de aprender con los ejemplos y ser eficientes.

Para realizar el análisis de clasificación de los subsectores industriales sobre aquellos que están orientados al mercado externo y de los que solo se dedican a la producción de bienes, existen muchas técnicas estadísticas pero las que se han utilizado en estos últimos tiempos han sido las herramientas de redes neuronales y multivariadas. De las cuales, la técnica con la que se han obtenido resultados satisfactorios han sido las redes neuronales artificiales, ya que es una herramienta que está emergiendo en los diferentes áreas de investigación: investigación de mercados, análisis financiero y macroeconómicos, farmacéuticos y consultaría de negocios, haciéndose uso en los diversos campos del conocimiento: reconocimiento de patrones, predicción en series temporales, clasificación de datos, entre otros. Mientras que las herramientas multivariadas solo tienen mayor trascendencia en lo que se refiere a la investigación de mercados.

Mediante el uso de las técnicas de redes neuronales artificiales se obtendrá la eficiencia en la clasificación de los subsectores industriales, minimizando el porcentaje de error en base al modelo determinado a través de esta técnica y validado por una serie de procesos y pruebas. Asimismo, este modelo permitirá en su uso posterior la clasificación de nuevos datos. La eficiencia de las redes neuronales en la construcción de un modelo está en que la técnica no requiere suposición sobre la forma de distribución de los datos, supuestos que muy pocas veces se cumplen principalmente tratándose de variables económicas.

Por tanto, mediante la aplicación de esta metodología se pretende conocer el comportamiento de los subsectores Industriales que han orientado su producción al mercado externo o interno; evaluando así su nivel de

competitividad y siendo posible identificar los subsectores que no presentan competitividad, debido a que posiblemente orienten su producción de bienes al mercado interno.

ANTECEDENTES

En la mayoría de los países latinoamericanos se pueden encontrar trabajos de investigación sobre la aplicación de las redes neuronales artificiales a un creciente número de problemas reales de considerable complejidad, tales como reconocimiento de patrones, clasificación de datos, predicción, entre otros, desarrollándose en los campos de la investigación de mercados, análisis financiero, consultoría de negocios y en otros campos.

Entre los trabajos de investigación que han permitido evaluar y realizar la clasificación de los subsectores industriales con respecto a la competitividad en la industria manufacturera frente a otros mercados, del cual se ha tomado como base a uno de ellos ha sido el desarrollado por la Comisión Económica para América Latina (2000)³, donde utiliza como metodología de aplicación las técnicas matemáticas para realizar la identificación de los subsectores productivos y competitivos, este trabajo ha permitido la identificación de variables económicas para ser implementado en la tesis, las cuales han sido relevantes luego de aplicarse un análisis estadístico de la información a utilizarse.

Otro documento de trabajo del cual se ha tomado como referencia para la identificación de variables significativas en la construcción del modelo de redes neuronales se menciona el trabajo desarrollado por Horta, Roberto y Jung, Andrés (2003) donde realiza un marco de análisis de la “Competitividad e Industria Manufacturera” a fin de analizar la competitividad de los principales subsectores industriales, determinando sus principales factores y posibles acciones para su mejora en la economía uruguaya. Además, de haber permitido detectar algunos aspectos de cambio estructural asociados a su inserción externa.

³ Trabajo de investigación desarrollado por la CEPAL, la cual consistió en estimar un indicador de competitividad neto de importaciones y exportaciones utilizando para ello el software CAN-PLUS.

Jiménez Félix, Apolo G. y Kapsoli J. (1998) desarrolló un trabajo de investigación donde se examinan los determinantes de la “Competitividad de la Industria Manufacturera Peruana” mediante un modelo económico que incluye como variables explicativas fundamentales; la productividad de mano de obra y el costo relativo del trabajo. Como aporte de la presente tesis se pretende desarrollar como una variante la aplicación de las redes neuronales en la construcción de un modelo de competitividad, para analizar la orientación productiva y competitiva de los subsectores industriales de la manufactura peruana.

Para el análisis de comparaciones de los resultados y validez de los mismos, así como la significación de las variables económicas relevantes en el modelo de redes neuronales nos basamos en los siguientes estudios:

Torres, Zorrilla Jorge (2003) presenta un estudio de “Análisis de los clusters de los sectores manufactureros” donde describe las empresas más importantes de los clusters, los eslabonamientos productivos, el destino final de los productos, y la propiedad de algunas de las empresas consideradas. Concluye que los clusters industriales todavía están en su primera etapa de formación y que existen limitaciones en relación a las bajas capacidades tecnológicas existentes, a la capacidad de generar innovaciones y difundir aprendizajes, a la insuficiencia de demanda interna que permita escalas mínimas de producción, y a las dificultades actuales para un mayor financiamiento y para inversión directa extranjera. Asimismo, concluye que los clusters industriales más desarrollados son los complejos de exportación de la economía: Minería-Metalurgia, Pesca, y Textiles.

Torrente, Daniela y Gusinsky de Gelman, Susana (2001) realizó un estudio de la “Competitividad de la industria argentina y chaqueña”, la cual consiste en el análisis de los datos y confirmación o rechazo de las hipótesis: la industria manufacturera en el chaco no favorece su crecimiento dado el contexto de la globalización en el cual le toca desarrollarse, siendo aceptada parcialmente como una de las causas de la desindustrialización a nivel provincial, ya que el

principal determinante de este proceso en la provincia fue la legislación de promoción industrial. En conclusión de lo desarrollado se desprende que el estudio de la competitividad es de fundamental importancia tener en cuenta el como un área de estudio clave la legislación de promoción industrial y la legislación que rige el desenvolvimiento de la actividad económica.

Otros estudios relacionados a la orientación exportadora de la industria a nivel nacional e internacional donde se analiza la identificación y clasificación de los subsectores industriales más competitivos durante el periodo de análisis, ha permitido presentar los resultados de la información procesada en la tesis generando un rango denominado “cuadrantes” que representan los niveles de competitividad, siendo utilizados en los valores obtenidos mediante el modelo de redes neuronales desarrollado. No obstante, tales estudios que se mencionan a continuación han utilizado las técnicas económicas y estadísticas para la construcción del modelo de competitividad.

Jiménez Félix, Aguilar Giovanna y Kapsoli Javier (1998) ha desarrollado un estudio de la “Competitividad, rendimientos crecientes y comercio intra-industrial en la manufactura peruana” donde muestra que las ganancias de competitividad se concentran sólo en aquellas ramas industriales que presentan rendimientos crecientes a escala estadísticamente significativos y, por otro lado, que se ha reducido la presencia e importancia del comercio intra-industrial en los últimos años. La corroboración empírica se realiza con un modelo que permite identificar directamente el tipo de rendimientos existente en cada una de las 32 ramas que conforman dicho sector. La estimación econométrica del modelo permite, además, ponderar la importancia que los factores de demanda tienen para explicar la tendencia y dinámica del crecimiento y de la acumulación de capital en el sector manufacturero.

Por otro lado, Saavedra Jaime (1996) presenta un estudio de “La liberalización comercial de la industria manufacturera en el Perú”, donde evalúa de manera empírica el impacto de las reformas de comercio exterior sobre la estructura de la producción, el patrón de comercio exterior, capital extranjero y el

empleo manufacturero, y concluye que los factores externos de competitividad están relacionados en el mercado interno por la productividad laboral y las inversiones extranjeras directas.

Frente a estos antecedentes, la presente tesis desarrolla como una variante la aplicación de las técnicas de redes neuronales en la competitividad de la industria manufacturera peruana; debido a que no se han encontrado estudios recientes que hayan analizado la situación productiva y competitiva de la industria mediante ésta técnica, sin embargo, se han aplicado en otros sectores económicos como finanzas y comercio. Siendo la industria que juega un rol importante como sector productivo en la economía después del sector minero, es de gran importancia conocer al interior del sector, la competitividad de las actividades que integran, para ello se realiza un análisis de comparación de técnicas empleadas (modelos neuronales y modelos estadísticos) en la presente tesis, a fin de mostrar la eficiencia de los modelos de redes neuronales con aplicación en la clasificación de los subsectores industriales competitivos, minimizando el porcentaje de error de clasificación frente a ésta técnica convencional.

Debido a que en los últimos años se han producido un importante avance en el desarrollo de nuevas técnicas inteligentes para tratar diversos problemas relacionados con el análisis de datos cuya formulación mediante técnicas clásicas resultan difíciles o inapropiadas. Las redes neuronales artificiales tienen una base teórica sólida y práctica que han demostrado ser herramienta útil para tareas tales como clasificación y predicción. Esta técnica está siendo usada en diversos campos de investigación, mostrando ser eficiente que las técnicas estadísticas clásicas. La metodología de retropropagación de errores (*backpropagation*) mediante un esquema de aprendizaje supervisado, ha sido utilizada satisfactoriamente en tareas de ajuste funcional (predicción, series temporales, modelado), principalmente en el proceso de clasificación. Siendo ésta la red neuronal por excelencia, empleada en más del setenta por ciento de los casos.

Fogelman (1998) afirma que en la actualidad los modelos MLP, SOFM, LVQ y RBF⁴ cubren el 90% de las aplicaciones prácticas de redes neuronales.

Asimismo, se han realizado estudios y proyectos de investigación sobre temas de clasificación de datos y creación de indicadores económicos con aplicación de las redes neuronales, que han alcanzado un alto nivel de eficiencia frente a otras técnicas estadísticas y modelos matemáticos, además de mostrar gran importancia para la toma de decisiones de la alta dirección de la empresa.

Los estudios que se mencionan a continuación con un resumen detallado han permitido tener un panorama más amplio sobre el empleo de las técnicas de redes neuronales, proporcionando así una visión de las etapas de procesamiento, selección de variables significativas en el modelo y las pruebas (*test*) respectivas ha realizarse para la generación de un modelo neuronal óptimo, ya que se encuentran relacionados con nuestro objetivo de generar un modelo neuronal que evalúe la competitividad del sector industrial manufacturero. También, se encuentran muy detallados los procedimientos para la construcción de un modelo neuronal con aplicaciones de clasificación y predicción de indicadores, donde se realizan las comparaciones de las redes neuronales con las técnicas estadísticas a través de los parámetros obtenidos.

Entre sus aplicaciones se tiene un reciente estudio de “Indicadores líderes, redes neuronales y predicción de corto plazo” desarrollado por Kapsoli Salinas Javier y Bencich Aguilar Brigitt (2002) donde muestra un procedimiento para construir un predictor de corto plazo del nivel de actividad económica (Producto Bruto Interno), utilizando para ello el filtro de Baxter & King para descomponer la serie de PBI mensual en sus tres componentes: estacional, cíclico y tendencial. Posteriormente el componente cíclico es estimado y pronosticado a partir de un conjunto de variables líderes que adelantan al PBI. Se propone que las relaciones entre estas variables y el ciclo del PBI se dan a través de un modelo no lineal de redes neuronales. Con este aporte y el rápido desarrollo de la tecnología de las

⁴ Los modelos de las RNA más comunes Perceptrón multicapa (MPL), Mapas autoorganizados de Kohonen (SOFM), Funciones de base radial (RBF) y Cuantización del vector aprendizaje (LVQ) utilizados en la clasificación de patrones.

computadoras personales, el uso de los modelos no lineales de redes neuronales para fines de predicción ha ido ganando popularidad en el terreno de la economía y las finanzas [Franses & Van Dijk, 2000].

La investigación realizada por Jagric Timotej (2003) sobre “Una aproximación no lineal para predicciones con indicadores económicos líderes”, se basa en la construcción de un modelo de indicadores líderes con recientes desarrollos en análisis de series de tiempo, como una nueva aproximación en predicción utilizando indicadores líderes basados en redes neuronales. Los resultados empíricos presentados para predecir el índice de la producción industrial, muestran un rendimiento superior frente a los modelos clásicos. Esta investigación ha permitido en la tesis analizar las variables macroeconómicas; su consistencia e inclusión en el modelo. Además, en determinar el tipo de arquitectura a emplearse, a fin de elegir una adecuada función de activación para generar los índices predecidos en la capa de salida. Tales resultados obtenidos muestran a las actividades económicas (CIUs) competitivos y no competitivos según el rango establecido para la clasificación de los índices de competitividad.

El documento de investigación presentado por Shachmurove Yochanan y Witkowska Dorota (2001) sobre “La aplicación de las redes neuronales artificiales en las correlaciones dinámicas entre los principales mercado de valores del mundo”, cuenta con una base de datos de índices de valores de los principales mercados del mundo: Canadá, Francia, Alemania, Japón, Reino Unido, Estados Unidos. Se basa en el criterio de la raíz cuadrado medio del error, error máximo absoluto y el valor de la función objetivo para determinar que los modelos perceptrón multicapa con funciones de activación logística predicen mejor los índices diarios de retorno comparado con los modelos de mínimos cuadrados ordinarios y lineal general tradicionales. Asimismo, manifiesta que un modelo perceptrón multicapa con cinco unidades en la capa oculta predice mejor los índices de valores para Estados Unidos, Francia, Alemania, Reino Unido y el mundo, que una red neuronal con dos elementos. Por tanto, concluye que puede ser utilizado como una herramienta para el análisis financiero. La presente tesis

ha fundamentado su estructura y aplicación en la metodología empleada por el estudio mencionado, particularmente, en los criterios estadísticos utilizados para comparar resultados empíricos obtenidos mediante los modelos neuronales y los modelos tradicionales, obteniendo buenos resultados en la generación de indicadores macroeconómicos para un periodo de tiempo en estudio.

El Centro de Estudios Latinoamericanos (CELA) de la Pontificia Universidad Católica del Ecuador (2001) realizó un estudio sobre “Los impactos de las políticas de ajuste estructural sobre el empleo y las condiciones de vida de los ecuatorianos” usando con herramienta de ingeniería para la creación de modelos mediante la técnica de redes neuronales, a fin de explicar el empleo y la pobreza. Los resultados obtenidos se sintetizan a continuación: de acuerdo a los modelos de redes neuronales realizados durante esta investigación, la variable más influyente en la explicación de la tasa de desempleo estaría vinculada al comportamiento del sector moderno de la economía: la capacidad de generación de empleo adecuado por parte de la economía ecuatoriana estaría asociada en relación con un buen desempeño de su sector moderno. En el caso de los modelos para pobreza, los resultados muestran que la variable que más influye en el comportamiento de la pobreza sería la ocupación con un 30.22% en tanto que la precarización del mercado laboral contribuye con un 14%.

El estudio de investigación desarrollado por Mallo González, Carlos (2003) realiza una introducción a los modelos neuronales y explora su aplicabilidad en el terreno de la economía cuantitativa como instrumento de modelización y predicción no paramétrica. De esta manera ha desarrollado “Un modelo de Red Neuronal Artificial aplicado en la predicción de la demanda horaria de energía eléctrica”. Los resultados obtenidos fueron comparados con los ofrecidos por las metodologías convencionales de ajuste y predicción. De tal forma que el modelo neuronal propuesto ha sido capaz de predecir la evolución horaria de la demanda eléctrica con una precisión del 98%.

Noket, S., Britos, P. y García Martínez, R. (2003) desarrollaron un estudio de “Pronóstico de ventas basada en la comparación de la técnicas de redes

neuronales y método estadístico”, con el objetivo de evaluar la eficiencia de las redes neuronales y establecer los entornos más adecuados para su uso. En dicho trabajo se utilizó una red neuronal *backpropagation* para predecir la variable ventas debido a que esta arquitectura es útil en aplicaciones de clasificación de patrones, de tal forma que llegaron a la conclusión que la técnica de redes neuronales es más eficiente que las técnicas estadísticas.

Un estudio donde se realizó una comparación de dos técnicas: las redes neuronales y la econométrica, fue desarrollado por Mat Junoh, Mohd (2004) siendo el tema “Predicciones del crecimiento del PBI de Malasia usando indicadores económicos basados en conocimiento: una comparación entre las redes neuronales y las estimaciones econométricas”, cuyo propósito del documento es extender la técnica de las redes neuronales a la inclusión de modelos predictivos debido a que presenta dos ventajas elementales. Primero, no requiere de asumir la distribución poblacional de las variables, y segundo, se usa cuando las entradas son altamente correlacionadas, con datos faltantes o donde el sistema es no lineal. Finalmente, concluye para la aplicación desarrollada que las técnicas de redes neuronales tiene un gran potencial comparado con la estimación econométrica tradicional. Tal metodología y análisis desarrollado en el documento ha permitido en la tesis, determinar la estructura y clasificación de patrones mediante el modelo de redes neuronales establecido (Perceptrón multicapa con retropropagación de errores), asimismo, a partir de ello se elige un criterio de análisis estadístico para comparar metodologías, ya que en la presente tesis se presenta una comparación entre las técnicas de redes neuronales y estadísticas (aplicación del análisis multivariado).

Pitarque Alfonso, Roy Juan Francisco y Ruíz Juan Carlos (1998) realiza un estudio sobre “Redes Neurales versus Modelos estadísticos: Simulaciones sobre tareas de predicción y clasificación” donde se comparan mediante simulación de redes neuronales (del tipo perceptrón multicapa) con modelos estadísticos (regresión múltiple, análisis discriminante y regresión logística) en tareas de predicción y clasificación (binaria o no binaria), manipulando los patrones de

correlación existentes entre los predictores (o variables de entrada) y entre predictores con el criterio (variable de salida). Los resultados muestran que en tareas de predicción las redes neurales y modelos de regresión múltiple tienden a rendir por igual. Sin embargo, en las tareas de clasificación de todo tipo de condiciones las redes neurales rinden mejor que los modelos estadísticos de análisis discriminante y regresión logística.

Montaño Moreno Juan (2002) desarrolla un trabajo de investigación sobre “Las redes neuronales artificiales aplicadas al análisis de datos” donde el estudio se centra en la importancia de las variables de entrada en una red de perceptrón multicapa siendo uno de los aspectos más críticos en la utilización de las RNAs orientadas al análisis de datos, debido a que el valor de los parámetros obtenidos por la red no tienen una interpretación práctica a diferencia de un modelo de regresión clásico. Sin embargo, las RNAs se han presentado al usuario como variante a los modelos clásicos por su aplicación en diferentes campos de ingeniería y por resultados satisfactorios para la toma de decisiones.

El estudio realizado por García Estévez Pablo (2002) sobre “Las aplicaciones de las redes neuronales en finanzas” muestra el potencial de las redes neuronales supervisadas. La red ha sido capaz de calcular los precios de 596 contratos diferentes puestos al azar con una precisión del 98%. La red neuronal permite encontrar la existencia o no de la relación no lineal entre conjuntos de datos, por lo que los analistas pueden utilizarla para encontrar relaciones no estudiadas y realizar predicciones alternativas a las del mercado. Tal es el caso en el cálculo del precio, la opción viene dado por las relaciones que la red encuentra en las variables típicas utilizadas por el algoritmo *Black Scholes* mas el volumen de contratos. Una ventaja de este modelo sobre *Black Scholes* es la no utilización de la distribución normal estándar. Y es ventaja no sólo por los requerimientos cuantitativos a la hora del cálculo, sino por que algunos analistas pueden llegar a cuestionar que la evolución de los precios de las acciones se distribuya mediante esa ley estadística.

El estudio realizado por Romaní G., Aroca P., Aguirre N., Leiton P. y Muñoz J. (2000) sobre “Modelos de clasificación y predicción de quiebra de empresas: una aplicación a empresas chilenas”, compara tres modelos utilizados comúnmente, a fin de identificar cuál es el modelo que clasifica y predice, con mayor grado de confiabilidad la quiebra de empresas en Chile. Para ello, utiliza diferentes índices financieros, variables macroeconómicas y otras variables de control. Los modelos fueron aplicados a una muestra de 98 empresas, seleccionadas accidentalmente, sin restricción de giro comercial, 49 quebradas y 49 no quebradas. El resultado de la investigación muestra que si bien el modelo de redes neuronales resultó superior al modelo múltiple discriminante y al Logit en clasificación y predicción, también se requiere de otras herramientas para determinar el conjunto óptimo de variables a utilizar. La presente tesis se fundamenta en este aplicativo y brinda un aporte en el empleo de las herramientas estadísticas para determinar el conjunto de variables relevantes que deben ingresar al sistema, los cuales permitieron generar el indicador de competitividad y con ello realizar la clasificación de las actividades industriales con un mínimo margen de error (aproximándose a cero).

Limsombunchai Visit, Gan Christopher y Lee Minsoo (2004) presenta un estudio “Predicción del precio de una casa: Modelo de precio *hedonic* versus red neuronal artificial” donde compara empíricamente el poder predictivo de ambos modelos para la predicción del precio de una casa. Para ello toma una muestra de 200 casas en Christchurch, Nueva Zelanda; asimismo incluye factores relevantes como tamaño de la casa, tiempo, tipo, número de alcobas, número de baños, el número de garajes, conveniencias alrededor de la casa y situación geográfica para el procesamiento de la data, donde los resultados empíricos obtenidos soportan el potencial de las redes neuronales artificiales en la predicción de precio de casa en comparación al modelo “*hedonic*” según los parámetros de eficiencia. Este estudio ha permitido en la tesis comprender el proceso de funcionamiento de los modelos de perceptrón multicapa frente a una variable predictora obtenido en el proceso inicial, así como la identificación de los parámetros significativos para comparar modelos.

CAPITULO I

GENERALIDADES DE LAS REDES NEURONALES ARTIFICIALES Y EL MODELO DE SISTEMAS

1.1. REDES NEURONALES ARTIFICIALES

Las Redes Neuronales Artificiales (RNA) ha tomado diversos nombres dependiendo del área de aplicación en el que se vean inmersas, dichos nombres pueden ser: Sistemas Neuronales Artificiales (SNA), Neurocomputadoras, Procesadores Paralelos Distribuidos (PPD). Estos son solo algunos de ellos con que se conoce a los sistemas que tratan de simular, aunque de una manera parcial y simple, a la estructura y funcionamiento del cerebro y del sistema nervioso central de los seres vivos. Actualmente, aún con todas las investigaciones realizadas y con la tecnología existente, sigue sin entenderse el funcionamiento del cerebro, el cual es altamente complejo, y sería muy aventurado y pretencioso decir que una red neuronal artificial es un modelo representativo del cerebro. Se trata más bien de entender y tratar de reproducir el funcionamiento de sus elementos fundamentales: las neuronas.

De esta manera, se ha tratado de dar definiciones de lo que es una Red Neuronal, tales como:

- “Una Red Neuronal consiste en una serie de neuronas individuales (elementos procesadores). Cada neurona actúa como un elemento procesador independiente, las entradas y los pesos de interconexión son procesados por una función suma (típicamente una sumatoria de pesos), el resultado de esta

sumatoria es mapeado por una función de transferencia de característica no lineal (generalmente una función sigmoide). La salida de esta función no lineal es la salida de la neurona”.

- “Una Red Neuronal puede consistir en múltiples capas de neuronas interconectadas con otras neuronas en la misma o en diferentes capas. Una topología de conexión de la neurona con otras neuronas puede variar desde una completa interconexión de todas las neuronas de una capa con la posterior, hasta una conexión parcial. Las capas están referidas como capa de entrada, capa(s) intermedia(s) o capa de salida”.
- Las Redes Neuronales deben “aprender” cómo procesar la información de entrada antes de que ésta pueda ser utilizada en una aplicación. El proceso de entrenamiento de una red neuronal involucra el ajuste de los pesos de entrada en cada neurona hasta que la salida de la red se aproxima a la salida deseada. Este procedimiento involucra la creación de un archivo de entrenamiento, el cual está formado por los datos de cada nodo de entrada y la respuesta deseada para cada nodo de salida de la red. Una vez que la red está entrenada, sólo los datos de entrada son provistos a la red, la cual “recuerda” la respuesta que “aprendió” durante el entrenamiento.

La definición más simple de una Red Neuronal, es aquella que más hace referencia a una Red Neuronal Artificial. Existen numerosas formas de definir a las redes neuronales; desde las definiciones cortas y genéricas hasta las que intentan explicar más detalladamente qué son las redes neuronales. Una definición más formal sería:

“Redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico” (Rojas, R.1995)

1.1.1. FUNDAMENTOS BIOLÓGICOS

Las redes neuronales son otra forma de emular otra de las características propias de los humanos: la capacidad de memorizar y asociar hechos. Si examinamos con atención aquellos problemas que no pueden expresarse a través de un algoritmo nos daremos cuenta de que todos ellos tienen una característica común: la experiencia. El hombre es capaz de resolver estas situaciones acudiendo a la experiencia acumulada. Así, parece claro que una forma de aproximarse al problema consiste en la construcción de sistemas que sean capaces de reproducir esta característica humana. En definitiva, las redes neuronales no son más que un modelo artificial y simplificado del cerebro humano, que es el ejemplo más perfecto del que disponemos de sistema que es capaz de adquirir conocimiento a través de la experiencia. Una red neuronal es un nuevo sistema para el tratamiento de la información cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano, la neurona.

La neurona y la sinapsis

El cerebro humano contiene aproximadamente 12 billones de células nerviosas o neuronas. Cada neurona tiene de 5,600 a 60,000 *conexiones dendríticas* provenientes de otras neuronas. Estas conexiones transportan los impulsos enviados desde otras neuronas y están conectadas a la membrana de la neurona. Cada neurona tiene una salida denominada *axón*. El contacto de cada axón con una dendrita se realiza a través de la *sinapsis*. Tanto el axón como las dendritas transmiten la señal en una única dirección.

La sinapsis consta de un extremo presináptico de un axón conectado a un extremo postsináptico de una dendrita, existiendo normalmente entre éstos un espacio denominado *espacio sináptico*.

Las neuronas son eléctricamente activas e interactúan entre ellas mediante un flujo de corrientes eléctricas locales. Estas corrientes se deben a diferencias de potencial entre las membranas celulares de las neuronas. Un impulso nervioso es un cambio de voltaje que ocurre en una zona localizada de la membrana celular. El impulso se transmite a través del axón hasta llegar a la sinapsis, produciendo

la liberación de una sustancia química denominada *neurotransmisor* que se esparce por el fluido existente en el espacio sináptico. Cuando este fluido alcanza el otro extremo transmite la señal a la dendrita. Los impulsos recibidos desde la sinapsis se suman o restan a la magnitud de las variaciones del potencial de la membrana. Si las contribuciones totales alcanzan un valor determinado (alrededor de 10 milivoltios) se disparan uno o más impulsos que se propagarán a lo largo del axón.

Aunque todavía no está del todo claro, parece que este impulso se inicia en la conexión entre el axón y la membrana. Su amplitud y velocidad dependen del diámetro del axón y su frecuencia del número de disparos que se efectúen.

Las redes neuronales artificiales basan su funcionamiento en las redes neuronales reales, las cuales están formadas por un conjunto de unidades de procesamiento conectadas entre sí. Por analogía con el cerebro humano se denomina neurona a cada una de estas unidades de procesamiento. Cada neurona recibe muchas señales de entrada y envía una única señal de salida (como ocurre en las neuronas reales).

1.1.2. MODELO GENERAL DE UNA RED NEURONAL ARTIFICIAL

La estructura genérica de una neurona artificial está descrita en el marco establecido por el grupo PDP (*Parallel Distributed Processing Research Group*, de la Universidad de California en San Diego⁵).

El procesador elemental o neurona es representado a partir de un vector de entrada procedente del exterior o de otras neuronas, que proporciona una única respuesta o salida.

Los elementos que constituyen la neurona de etiqueta i son los siguientes:

- Conjunto de entradas, $x_j(t)$.
- Pesos sinápticos de la neurona i , w_{ij} que representan la intensidad de interacción entre cada neurona presináptica j y la neurona postsináptica i .

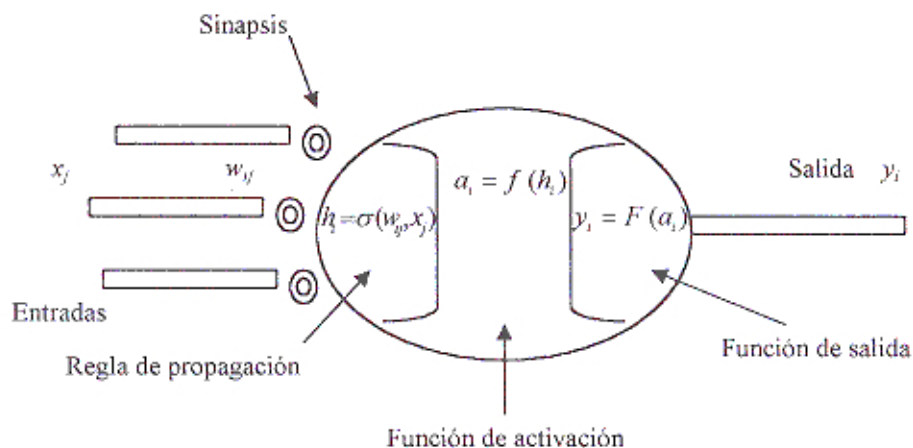
⁵ Grupo de investigación de RNA, responsables en gran medida del renacimiento de las redes neuronales a mediados de los ochenta, cuyo trabajo se publicó en dos volúmenes considerados clásicos [Rumelhart 86a, MacClelland 86].

- Regla de propagación $\sigma_i(w_{ij}, x_j(t))$, que proporciona el valor del potencial postsináptico $h_i(t) = \sigma_i(w_{ij}, x_j(t))$, de la neurona i en función de sus pesos y entradas.
- Función de activación $f_i(a_i(t-1), h_i(t))$, que proporciona el estado de activación actual $a_i(t) = f_i(a_i(t-1), h_i(t))$, de la neurona i , en función de su estado anterior $a_i(t-1)$ y de su potencial postsináptico actual.
- Función de salida $F_i(a_i(t))$, que proporciona la salida actual $y_i(t) = F_i(a_i(t))$ de la neurona i en función de su estado de activación.

De este modo, la operación de la neurona i puede expresarse como:

$$y_i(t) = F_i(f_i[a_i(t-1), \sigma_i(w_{ij}, x_j(t))])$$

Esquemáticamente quedaría representada por:



Entradas y salidas

Las variables de entrada y salida pueden ser binarias (digitales) o continuas (analógicas). Dependiendo del modelo y aplicación. En el caso de un perceptrón multicapa admite ambos tipos de señales. Así, para tareas de clasificación poseería salidas digitales $\{0,+1\}$, mientras que para un problema de ajuste funcional de una aplicación multivariante continua, se utilizarían salidas continuas pertenecientes a un cierto intervalo. Dependiendo del tipo de salida, las

neuronas suelen recibir nombres específicos [Müller 90]. En ocasiones, el rango de valores que una neurona de salida continua puede proporcionar suele limitarse a un intervalo definido por: $[0,+1]$ o $[-1,+1]$.

Regla de propagación

La regla de propagación permite obtener, a partir de las entradas y los pesos el valor potencial postsináptico h_i de la neurona

$$h_i(t) = \sigma_i(w_{ij}, x_j(t))$$

La función más habitual es de tipo lineal, y se basa en la suma ponderada de las entradas con los pesos sinápticos

$$h_i(t) = \sum_j w_{ij} x_j$$

Que formalmente también puede interpretarse como el producto escalar de los vectores de entrada y pesos.

$$h_i(t) = \sum_j w_{ij} x_j = \mathbf{w}_i^T \cdot \mathbf{X}$$

El peso sináptico w_{ij} se define como la intensidad de interacción entre la neurona presináptica j y la postsináptica i . Dada una entrada positiva (procedente de un sensor o simplemente la salida de otra neurona), si el peso es positivo tenderá a excitar a la neurona postsináptica, si el peso es negativo tenderá a inhibirla. Así se habla de sinapsis excitadoras (de peso positivo) e inhibidoras (de peso negativo).

Función de activación

La función de activación o de transferencia proporciona el estado de activación actual $a_i(t)$ a partir del potencial postsináptico $h_i(t)$ y del propio estado de activación anterior $a_i(t-1)$.

$$a_i(t) = f_i(a_i(t-1), h_i(t))$$

Sin embargo, en muchos modelos de RNA se considera que el estado actual de neurona no depende de su estado anterior, sino únicamente del actual.

$$a_i(t) = f_i(h_i(t))$$

En cuanto a las funciones de activación existe un gran número inspiradas, todas ellas, en razones biológicas. Algunas de estas funciones son:

a) Función signo o umbral

$$Salida = \begin{cases} 1 & U_n \geq 0 \\ 0 & U_n < 0 \end{cases}$$

Cuando una neurona usa esta función de activación se habla del modelo de McCulloch-Pitts⁶.

b) Función lineal a tramos

$$Salida = \begin{cases} 1 & U_n \geq \frac{1}{2} \\ U_n & \frac{1}{2} > U_n > \frac{1}{2} \\ 0 & U_n < \frac{1}{2} \end{cases}$$

c) Función Sigmoidea

$$Salida = \frac{1}{1 + e^{(-a \cdot U_n)}}$$

⁶ Modelo orientado a aplicaciones prácticas, cuya característica principal es la formulación de la neurona artificial como dispositivo no lineal, es decir, la respuesta de las neuronas biológicas es de tipo no lineal.

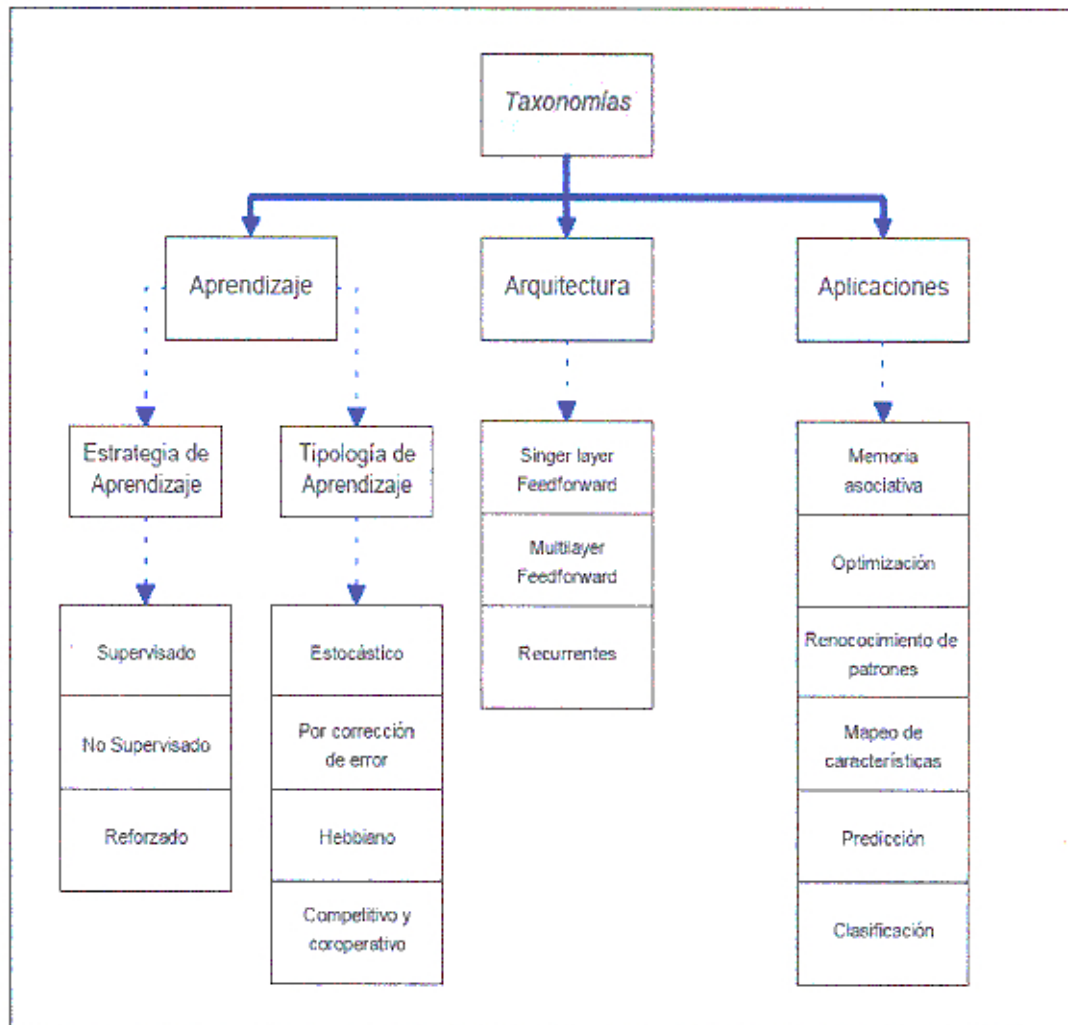
Las funciones que se han definido varían entre 0 y 1; asimismo a partir de ellas se pueden definir otras funciones que varían entre -1 y 1.

Función de salida

Esta función proporciona la salida global de la neurona $y_i(t)$ en función de su estado de activación actual $a_i(t)$. Muy frecuentemente la función de salida es simplemente la identidad, $F(x)=x$, de modo que el estado de activación de la neurona se considera como la propia salida.

Dada la gran variedad de modelos neuronales existentes en la actualidad es necesaria en cierta medida la realización de una clasificación o *taxonomía*. De esta forma, los modelos neuronales se pueden clasificar desde una triple óptica: en función de la forma de aprendizaje, arquitectura y el área de aplicaciones. Tal como se presenta en la siguiente ilustración:

Ilustración N° 1: *Taxonomía*




1.1.3. ARQUITECTURA

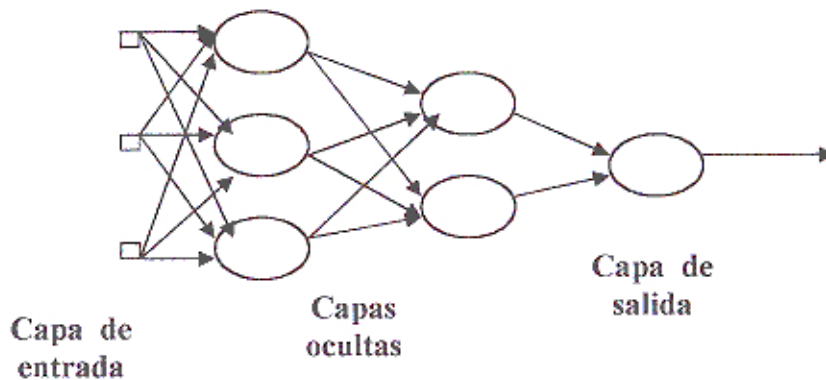
Una vez definidos los elementos básicos de toda red neuronal se procede a enumerar las diferentes estructuras en las que estos elementos se pueden asociar. Entre ellos se mencionan:

- a) **Redes Neuronales Monocapas:** Corresponde a una red neuronal más sencilla, ya que tiene una capa de neuronas que proyectan las entradas a una capa de neuronas de salida donde se realizan diferentes cálculos. La capa de entrada, por no realizar ningún cálculo, no se cuenta de ahí el nombre de


redes neuronales con una sola capa. Una aplicación típica de este tipo de redes es su uso como memorias asociativas.



- b) **Redes Neuronales Multicapas:** Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida (capas ocultas). Este tipo de red puede estar total o parcialmente conectada.



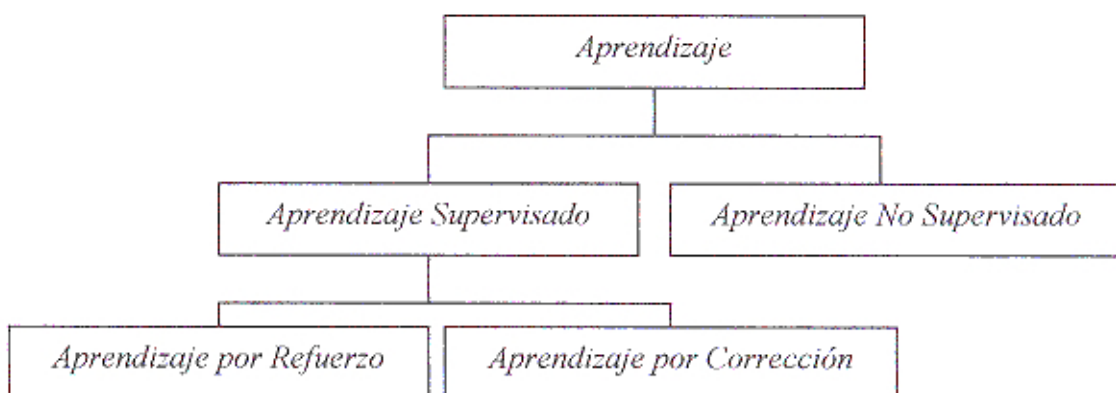
- c) **Redes Neuronales Recurrentes:** Se diferencian de las anteriores en la existencia de lazos de realimentación en la red. Estos lazos pueden ser entre neuronas de diferentes capas, neuronas de la misma capa o, más sencillamente, entre una misma neurona. Esta estructura recurrente la hace especialmente adecuada para estudiar la dinámica de sistemas no lineales.



1.1.4. METODO DE APRENDIZAJE

En una red neuronal es necesario definir un procedimiento por el cual las conexiones del dispositivo varíen para proporcionar la salida deseada (algoritmo de aprendizaje). De este modo el aprendizaje puede definirse como el proceso por el que se produce el ajuste de los parámetros libres de la red a partir de un proceso de estimulación por el entorno que rodea la red. El tipo de aprendizaje es determinado por la forma en la que dichos parámetros son adaptados. En la mayor parte de las ocasiones el aprendizaje consiste simplemente en determinar un conjunto de pesos sinápticos que permita a la red realizar correctamente el tipo de procesamiento deseado.

Los métodos de aprendizaje se pueden dividir en las siguientes categorías:



La primera gran división en los métodos de aprendizaje es entre algoritmos supervisados y no supervisados. En los *algoritmos no supervisados* no se conoce la señal que debe dar la red neuronal (señal deseada). La red en este caso se organiza ella misma agrupando, según sus características, las diferentes señales de entrada. Estos sistemas proporcionan un método de clasificación de las diferentes entradas.

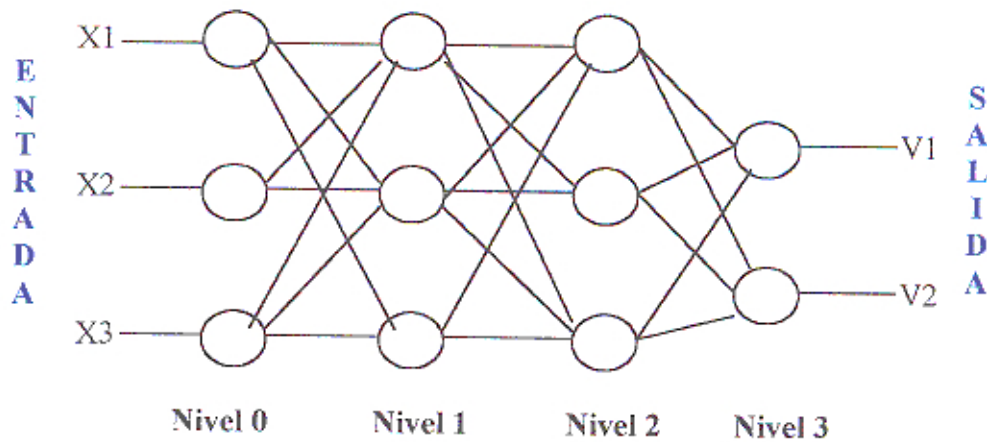
El *aprendizaje supervisado* presenta a la red las salidas que debe proporcionar ante las señales que se le presentan. Se observa la salida de la red y se determina la diferencia entre ésta y la señal deseada. Posteriormente, los pesos de la red son modificados de acuerdo con el error cometido. Este aprendizaje admite dos variantes: aprendizaje por refuerzo o aprendizaje por corrección. En el *aprendizaje por refuerzo* sólo conocemos si la salida de la red se corresponde o no con la señal deseada, es decir, nuestra información es de tipo *booleana* (verdadero o falso). En el *aprendizaje por corrección* conocemos la magnitud del error y ésta determina la magnitud en el cambio de los pesos.

1.2. MODELO DE PERCEPTRON MULTICAPA - MPL

El modelo de perceptrón multicapa es una red de tipo *feedforward* compuesta de varias capas de neuronas entre la entrada y la salida de la misma. Si se añade capas intermedias (ocultas) a un perceptrón simple, se obtiene un perceptrón multicapa o MPL (*Multi-Layer Perceptron*). Esta arquitectura suele entrenarse mediante el algoritmo denominado Retropropagación de errores o *Backpropagation* (BP), o bien haciendo uso de algunas de sus variantes o derivados. Motivo por el que muchas ocasiones el conjunto arquitectura MPL + *aprendizaje* BP suele denominarse red de Retropropagación o simplemente BP.

Retropropagación (*Backpropagation*) es un algoritmo de aprendizaje que se utiliza para entrenar redes de perceptrones de varios niveles. Fue creado por David E. Rumelhart, G.E Hinton y R.J. Williams (1986), aunque también fue propuesto independientemente por otros investigadores en la década de los 80's.

Esta arquitectura es definida como un algoritmo de aprendizaje supervisado con una base matemática fuerte; la cual puede verse como una generalización de la regla delta. Además de ser una técnica de minimización del error que aplica el concepto de gradiente descendente. Su objetivo es minimizar la función del error promedio al cuadrado que hay entre la salida real y la salida deseada de la red.



1.2.1. LA REGLA DELTA GENERALIZADA

La regla propuesta por Windrow en 1960 (regla delta) ha sido extendida a redes de capas intermedias (regla delta generalizada) con conexiones hacia delante (*feedforward*) y cuyas células tienen funciones de activación continuas (lineales o sigmoideas), dando lugar al algoritmo de Retropropagación (*Backpropagation*).

Estas funciones continuas son no decrecientes y derivables. La función sigmoideal pertenece a este tipo de funciones, a diferencia de la función escalón que se utiliza en el perceptrón simple, ya que esta última no es derivable en el punto en el que se encuentra la discontinuidad.

Este algoritmo utiliza también una función o superficie de error asociada a la red, buscando el estado estable de mínima energía o de mínimo error a través del camino descendente de la superficie del error. Por ello realimenta el error del sistema para realizar las modificaciones de los pesos en un valor proporcional al gradiente decreciente de dicha función del error.

1.2.1.1. FUNCIONAMIENTO DEL ALGORITMO

El método que sigue la regla delta generalizada para ajustar los pesos es exactamente el mismo que el de la regla delta generalizada en el perceptrón, es decir, los pesos se actualizan de forma proporcional a la delta, o diferencia entre la salida deseada y la obtenida ($\delta = \text{salida deseada} - \text{salida obtenida}$).

Dada una neurona (unidad U_j) y la salida produce y_j , el cambio que se produce en el peso de la conexión que une la salida de dicha neurona con la unidad $U_i(w_{ji})$, para un patrón de aprendizaje p está determinado por:

$$\Delta w_{ji}(t + 1) = \alpha \delta_{pj} y_{pi}$$

En donde el subíndice p se refiere al patrón de aprendizaje concreto y α es la constante o tasa de aprendizaje. El punto en el que difieren la regla delta generalizada de la regla delta es en el valor concreto de δ_{pj} . Por otro lado, en las redes multinivel, a diferencia de las redes sin neuronas ocultas, en principio no se puede conocer la salida deseada de las neuronas de las capas ocultas para poder determinar los pesos en función del error cometido. Sin embargo, inicialmente sí podemos conocer la salida deseada de las neuronas de salida. Según esto, si consideramos la unidad U_j de salida entonces definimos:

$$\delta_{pj} = (d_{pj} - y_{pj}) \cdot f'(z_j)$$

Donde d_{pj} es la salida deseada de la neurona j para el patrón p y z_j es la entrada neta que recibe la neurona j .

Esta fórmula es similar a la regla delta, excepto en lo que se refiere a la derivada de la función de transferencia.

1.2.1.2. ADICION DE UN MOMENTO EN LA REGLA DELTA GENERALIZADA

El método de retropropagación del error, también conocido como del gradiente descendente, requiere un importante número de cálculos para lograr el ajuste de los pesos de la red. En la implementación del algoritmo, se toma una amplitud de

paso que viene dada por la tasa de aprendizaje α . A mayor tasa de aprendizaje, mayor es la modificación de los pesos en cada iteración, con lo que el aprendizaje será más rápido, pero, por otro lado, puede dar lugar a oscilaciones. Rumelhart, Hinton y Williams (1986) sugirieron que para filtrar estas oscilaciones se añada en la expresión del incremento de los pesos un término (momento), β , de manera que dicha expresión quede:

$$w_{ji}(t+1) = w_{ji}(t) + \alpha \delta_{pj} y_{pi} + \beta (w_{ji}(t) - w_{ji}(t-1)) = \\ \Delta w_{ji}(t+1) = \alpha \delta_{pj} y_{pi} + \beta \Delta w_{ji}(t)$$

Donde β es una constante (momento) que determina el efecto en $t+1$ del cambio de los pesos en el instante t .

Con este momento se consigue la convergencia de la red en menor número de iteraciones, ya que si en t el incremento de un peso era positivo y en $t+1$ también. Entonces el descenso por la superficie de error $t+1$ es mayor. Sin embargo, si en t el incremento era positivo y en $t+1$ es negativo, el paso que da en $t+1$ es más pequeño, lo cual es adecuado, ya que eso significa que se ha pasado por un mínimo y que los pesos deben ser menores para poder alcanzarlo.

Resumiendo el algoritmo de Backpropagation queda finalmente:

$$w_{ji}(t+1) = w_{ji}(t) + [\alpha \delta_{pj} y_{pi} + \beta \Delta w_{ji}(t)]$$

Donde:

$$\delta_{pj} = (d_{pj} - y_{pj}) \cdot f'(z_j)$$

Si U_j es una neurona de salida, y

$$\delta_{pj} = \left(\sum \delta_{pk} w_{kj} \right) f'(z_j)$$

Si U_j no es una neurona de salida.

1.2.2. ESTRUCTURA Y APRENDIZAJE POR RETROPROPAGACIÓN DE ERRORES

En una red de *Backpropagation* existe una capa de entrada con n neuronas y una capa de salida con m neuronas y al menos una capa oculta de neuronas internas. Cada neurona de una capa (excepto la de entrada) recibe entradas de todas las neuronas de la capa superior y envía su salida a todas las neuronas de la capa posterior (excepto las de salida). No hay conexiones hacia atrás *feedback* ni laterales entre neuronas de la misma capa.

La aplicación del algoritmo *backpropagation* tiene dos fases, una hacia delante y otra hacia atrás. Durante la primera fase el patrón de entrada es presentado a la red y propagado a través de las capas hasta llegar a la capa de salida. Obtenidos los valores de salida de la red, se inicia la segunda fase, comparándose estos valores con la salida esperada para obtener el error. Se ajustan los pesos de la última capa proporcionalmente al error. Se pasa a la capa anterior con una retropropagación del error (*backpropagation*), ajustando convenientemente los pesos y continuando con este proceso hasta llegar a la primera capa. De esta manera se han modificado los pesos de las conexiones de la red para cada ejemplo o patrón de aprendizaje del problema, del que conocíamos su valor de entrada y la salida deseada que debería generar la red ante dicho patrón.

A diferencia de la regla delta en el caso del perceptron, la técnica *backpropagation* o generalización de la regla delta, requiere el uso de las neuronas cuya función de activación tiene que ser continua, y por tanto, diferenciable. Generalmente, la función utilizada para esta técnica es del tipo sigmoideal.

1.2.2.1. ALGORITMO DE ENTRENAMIENTO

Los pasos y fórmulas a utilizar para aplicar el algoritmo de entrenamiento se muestran a continuación:

Paso 1:

Inicializar los pesos de la red con valores pequeños aleatorios.

Paso 2:

Presentar un patrón de entrada, $X_p: x_{p1}, x_{p2}, \dots, x_{pN}$, y especificar la salida deseada que debe generar la red: d_1, d_2, \dots, d_M (si la red se utiliza como un clasificador, todas las salidas deseadas serán cero, salvo una, que será la de la clase a la que pertenece el patrón de entrada).

Paso 3:

Calcular la salida actual de la red, para ello presentamos las entradas a la red y se va calculando la salida que presenta cada capa hasta llegar a la capa de salida, la cual será la salida de la red y_1, y_2, \dots, y_M . Los pasos a seguir es lo siguiente:

- Se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada.

Para una neurona j oculta:

$$z_{pj}^h = \sum_{i=1}^N w_{ji}^h x_{pi} - \theta_j^h$$

Donde el índice h se refiere a magnitudes de la capa oculta; el subíndice p , al p -ésimo vector de entrenamiento, y j a la j -ésima neurona oculta. El término θ puede ser opcional, ya que actúa como una entrada más.

- Se calculan las salidas de las neuronas ocultas:

$$y_{pj} = f_j^h(z_{pj}^h)$$

- Se realizan los mismo cálculos para obtener las salidas de las neuronas de salida (capa o: *output*)

$$z_{pk}^o = \sum_{j=1}^L w_{kj}^o x_{pj} - \theta_k^o$$

$$y_{pk} = f_k^o(z_{pk}^o)$$

Paso 4:

Calcular los términos de error para todas las neuronas.

Si la neurona k es una neurona de la capa de salida, el valor de delta estará dada por:

$$\delta_{pk}^o = (d_{pk} - y_{pk}) \cdot f_k'(z_{pk}^o)$$

La función f , debe cumplir el requisito de ser derivable, lo que implica la imposibilidad de utilizar una función escalón. En general se dispone de dos formas de función de salida una de ellas es la lineal y la otra que será utilizada en nuestro caso es la función sigmoideal, ésta última representada definida por:

$$f_k(z_{jk}) = \frac{1}{1 + e^{-z_{jk}}}$$

La selección de la función de salida depende de la forma en que se decida representar los datos de salida: si se desea que las neurona de salida sean binarias, se utiliza la función sigmoideal, puesto que esta función es casi biestable y, además derivable.

Si la neurona j no es salida, entonces la derivada parcial del error no puede ser evaluada directamente. Por tanto, se obtiene el desarrollo a partir de valores que son conocidos y otros que pueden ser evaluados.

La expresión obtenida en este caso es:

$$\delta_{pj}^h = f_j'(z_{pj}^h) \sum_k \delta_{pk}^o W_{kj}^o$$

Donde se observa que el error en las capas ocultas depende de todos los términos de error de la capa de salida de aquí surge el término de propagación hacia atrás.

En particular, para la función sigmoideal se expresa como:

$$\delta_{pj}^h = x_{pj} (1 - x_{pj}) \sum_k \delta_{pk}^o W_{kj}^o$$

Donde k se refiere a todas las neuronas de la capa superior a la de la neurona j . Así, el error que se produce en una neurona oculta es proporcional a la suma de los errores conocidos que se producen en las neuronas a las que está conectada la salida de ésta, multiplicado cada uno de ellos por el peso de la conexión. Los umbrales internos de las neuronas se adaptan de forma similar, considerando que están conectados con pesos desde entradas auxiliares de valor constante.

Paso 5:

Actualización de los pesos

Para ello, se utiliza el algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la forma siguiente:

Para los pesos de las neuronas de la capa de salida:

$$w_{kj}^o(t+1) = w_{kj}^o(t) + \Delta w_{kj}^o(t+1);$$

$$\Delta w_{kj}^o(t+1) = \alpha \delta_{pk}^o y_{pj}$$

Y para los pesos de las neuronas de la capa de oculta:

$$w_{ji}^h(t+1) = w_{ji}^h(t) + \Delta w_{ji}^h(t+1);$$

$$\Delta w_{ji}^h(t+1) = \alpha \delta_{pj}^h x_{pi}$$

Paso 6: El proceso se repite hasta que el término de error

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2$$

Resulta aceptablemente pequeño para cada uno de los patrones aprendidos.

1.2.3. CONSIDERACIONES DEL ALGORITMO DE APRENDIZAJE

El algoritmo de *backpropagation* encuentra un valor mínimo de error (local o global) mediante la aplicación de pasos descendentes (gradiente descendente). Cada punto de la superficie de la función de error corresponde a un conjunto de valores de los pesos de la red. Con el gradiente descendente, siempre que se

realiza un cambio en todos los pesos de la red, se asegura el descenso de la superficie del error hasta encontrar el area más cercano, lo que hacer que el proceso de aprendizaje se detenga en un mínimo local de error.

1.2.3.1. CONTROL DE CONVERGENCIA

En las técnicas de gradiente decreciente es conveniente avanzar por la superficie de error con incrementos pequeños de los pesos. Esto se debe a que se tiene una información local de la superficie y se desconoce lo lejos o cerca que está del punto mínimo. Con grandes incrementos, se corre el riesgo de pasar por encima del punto mínimo sin conseguir estacionarse en él. Con incrementos pequeños aunque se tarde más en llegar, se evita que ocurra esto. El elegir un incremento adecuado influye en la velocidad con la que converge el algoritmo. Esta velocidad se controla a través de la constante de proporcionalidad o tasa de aprendizaje α . Normalmente, α debe ser un número pequeño (del orden de 0,05 a 0,25), para asegurar que la red llegue a asentarse en una solución. Un valor pequeño de α significa que la red tendrá que hacer un gran número de iteraciones. Si esa constante es muy grande, los cambios de pesos son muy grandes, avanzando muy rápidamente por la superficie de error, con el riesgo de saltar el mínimo y estar oscilando alrededor de él, pero sin poder alcanzarlo.

Lo recomendable es aumentar el valor de α a medida que disminuye el error de la red durante la fase de aprendizaje. Así, se acelera la convergencia, aunque sin llegar nunca a los valores de α demasiado grandes, que hace que la red oscilase alejándose demasiado del valor mínimo. Otra forma de incrementar la velocidad de convergencia consiste en añadir, un termino momento consistente en sumar una fracción del anterior cambio cuando se calcula el valor del cambio de peso actual. Este término adicional tiende a mantener los cambios de peso en la misma dirección.

Un último aspecto tener en cuenta es la posibilidad de convergencia hacia alguno de los mínimos locales que pueden existir en la superficie de error del espacio de pesos. En el desarrollo matemático que se ha realizado para llegar al algoritmo de retropropagación, no se asegura en ningún momento que el mínimo que se

encuentre sea global. Una vez que la red se asienta en un mínimo, sea local o global, cesa el aprendizaje, aunque el error siga siendo demasiado alto, si se ha alcanzado un mínimo local. En todo caso, si la solución es admisible desde el punto de vista del error, no importa si el mínimo es local o global o si se ha detenido en algún momento previo a alcanzar un verdadero mínimo.

1.2.3.2. DIMENSIONAMIENTO DE LA RED

No se pueden dar reglas concretas para determinar el número de neuronas o el número de capas de una red para resolver un problema concreto. Lo mismo ocurre al momento de seleccionar el conjunto de vectores de entrenamiento. En todos estos casos, lo único que se pueden dar algunas ideas generales deducidas de la experiencia de numerosos autores [Freeman 91].

Respecto al número de capas de la red, en general tres capas son suficientes (entrada-oculta-salida). Sin embargo, hay veces en que un problema es más fácil de resolver (la red aprende más deprisa) con más de una capa oculta. El tamaño de las capas, tanto de entrada como de salida, suele venir determinado por naturaleza de la aplicación. En cambio, decidir cuántas neuronas debe tener la capa oculta no suele ser tan evidente.

El número de neuronas ocultas interviene en la eficacia de aprendizaje y de generalización de la red. No hay ninguna regla que indique el número óptimo, en cada problema se debe ensayar con distintos números de neuronas para organizar la representación interna y escoger el mejor. La idea más utilizada, sobre todo en los sistemas simulados, consiste en tener el menor número posible de neuronas en la capa oculta, porque cada una de ellas otorga mayor carga de procesamiento en el caso de una simulación de software. En un sistema implementado en hardware, este problema no es crucial; sin embargo se habrá que tener en presente el problema de comunicación entre distintos elementos de proceso.

Es posible eliminar neuronas ocultas si la red converge sin problemas, determinando el número final en función del rendimiento global del sistema. Si la red no converge, es posible que sea necesario aumentarse número. Por otro lado, examinando los valores de los pesos de las neuronas ocultas periódicamente

en la fase de aprendizaje, se pueden detectar aquellas cuyos pesos cambian muy poco durante el aprendizaje respecto a sus valores iniciales, y reducir por tanto el número de neuronas que apenas participan en el proceso de aprendizaje.

1.2.3.3. INICIALIZACION Y CAMBIO DE PESOS

Es ideal para una adaptación rápida del sistema, inicializar los pesos con una combinación de valores (W) muy cercano al punto de mínimo error buscado. Pero es imposible, porque no se conoce a priori donde está el punto mínimo. Así, se parte de un punto cualquiera del espacio, inicializando los pesos con valores pequeños y aleatorios cualesquiera, al igual que los términos de umbral θ_i , que aparecen en las ecuaciones de entrada neta a cada neurona. Este valor de umbral se trata como un peso más que está conectado a una neurona ficticia de salida con valor igual a 1. La utilización de los términos umbral es opcional, pues en caso de utilizarse, es tratado exactamente igual a un peso más y participa como tal en el proceso de aprendizaje.

La expresión de entrada neta a cada neurona se describe como:

$$z_{pk} = \sum_{j=1}^L w_{kj} x_{pj} + \theta_k$$

Para una neurona de salida (k), si consideramos $\theta_k \equiv w_{k(L+1)}^o$; $x_{p(L+1)} \equiv 1$, se puede escribir la siguiente expresión:

$$z_{pk} = \sum_{j=1}^{L+1} w_{kj} x_{pj}$$

También, si se considera $\theta_k \equiv w_{k0}^o$; $x_{p0} \equiv 1$ podemos tomarla como:

$$z_{pk} = \sum_{j=0}^L w_{kj} x_{pj}$$

La modificación de los pesos puede realizarse cada vez que un patrón ha sido presentado, o después de haber acumulado los cambios de los pesos en un

número de iteraciones. El momento adecuado para cambiar los pesos dependerá de cada problema concreto.

1.2.4. DEDUCCION DE LA REGLA BACKPROPAGATION

En este punto se deduce las expresiones del algoritmo de retropropagación de gradiente o de *backpropagation*.

Al asignar inicialmente unos determinados valores para los pesos de la red, el error se sitúa en un punto de la superficie de error. La variación del error respecto a cada peso de la red representa el vector de máxima pendiente en un punto determinado de la superficie de error. El cambio que se realiza en cada peso para ajustar la red es proporcional a ese vector en una constante negativa. De esta manera el algoritmo de retropropagación hace que se vaya bajando por la superficie de error hasta alcanzar un mínimo, por lo tanto, se determina que el incremento de un peso w_{ji} de la red en una iteración, al procesar un patrón p , es proporcional al cambio de error e_p respecto a ese peso en una constante negativa; es decir, proporcional al gradiente descendiente:

$$\Delta w_{ji} = -\alpha \left(\frac{\partial e_p}{\partial w_{ji}} \right) \quad (1.2.4.1)$$

El error total está dado por:

$$e = \frac{\sum_{p=1}^P e_p}{P} \quad (1.2.4.2)$$

Teniendo en cuenta que p es el índice de los ejemplos introducidos y P es el número de ellos.

El incremento a realizar en los pesos es proporcional a la gradiente decreciente, aplicando la regla de la cadena a la expresión (1.2.4.1) se tiene:

$$\frac{\partial e_p}{\partial w_{ji}} = \frac{\partial e_p}{\partial z_j} \cdot \frac{\partial z_j}{\partial w_{ji}} \quad (1.2.4.3)$$

donde la derivada del error respecto a z_j indica cómo varía el error al variar la entrada a la neurona j , y la derivada de z_j con respecto a un peso indica cómo varía la entrada a la neurona j al variar el peso de la conexión que va de la neurona i a la neurona j .

El segundo término de la expresión (1.2.4.3) se expresa de la siguiente forma:

$$\frac{\partial z_j}{\partial w_{ji}} = \frac{\partial \sum_i w_{ji} y_{pi}}{\partial w_{ji}} = y_{pi} \quad (1.2.4.4)$$

si al primer término de la expresión (1.2.4.3) lo denotamos como:

$$\frac{\partial e_p}{\partial z_j} = -\delta_{pj} \quad (1.2.4.5)$$

La ecuación (1.2.4.3) resultante es:

$$\frac{\partial e_p}{\partial w_{ji}} = -\delta_{pj} y_{pi} \quad (1.2.4.6)$$

Por lo tanto, la ecuación (1.2.4.1) queda expresado por:

$$\Delta w_{ji} = -\alpha \delta_{pj} y_{pi} \quad (1.2.4.7)$$

donde α es la constante de proporcionalidad.

Para calcular el valor delta, se vuelve a aplicar la regla de la cadena:

$$\delta_{pj} = -\frac{\partial e_p}{\partial z_j} = -\left(\frac{\partial e_p}{\partial y_{pj}} \cdot \frac{\partial y_{pj}}{\partial z_j}\right) \quad (1.2.4.8)$$

el segundo término de la expresión (1.2.4.8) esta dado por:

$$\frac{\partial y_{pj}}{\partial z_j} = \frac{\partial(f(z_j))}{\partial z_j} = f'(z_j) \quad (1.2.4.9)$$

Para el cálculo del primer término se presenta debe distinguir dos casos:

- Si j es una célula de la capa de salida: entonces tiene la siguiente expresión

$$\frac{\partial e_p}{\partial y_{pj}} = \frac{\partial \frac{1}{2} \sum_j (d_{pj} - y_{pj})}{\partial y_{pj}} = -(d_{pj} - y_{pj}) \quad (1.2.4.10)$$

De esta manera, la variación del peso de una conexión que va de una capa de la red a la capa externa se calcula como:

$$\Delta w_{ji} = \alpha (d_{pj} - y_{pj}) \cdot f'(z_j) y_{pi} \quad (1.2.4.11)$$

donde $(d_{pj} - y_{pj})$ es el error que se produce en las neurona de la capa externa, siendo d_{pj} el valor deseado para el patrón p , asimismo, y_{pj} el valor realmente obtenido al procesar el patrón p .

- Si la neurona j no pertenece a la capa externa: en este caso se aplica de nuevo la regla de la cadena.

$$\frac{\partial e_p}{\partial y_{pj}} = \sum_k \left(\frac{\partial e_p}{\partial z_k} \cdot \frac{\partial z_k}{\partial y_{pj}} \right) \quad (1.2.4.12)$$

donde k denota a las neuronas de la capa siguiente a la que pertenece la neurona j . Para el desarrollo de la ecuación (1.2.4.12) se utiliza la siguiente expresión $z_j = \sum_i w_{ji} y_i$; De esta manera, la variación del peso de una conexión que va de una capa de la red a otra que no sea externa, se calcula como:

$$\Delta w_{ji} = \alpha \sum_k (\partial_{pk} w_{kj}) \bullet f'(z_j) y_{pi} \quad (1.2.4.13)$$

Únicamente quedando la función f y su derivada por definir, basándonos en una función sigmoïdal donde su derivada se expresa $f'(z_j) = y_j(1 - y_j)$, de esta manera el incremento a realizar en los pesos existentes entre una capa y la siguiente que no sea la capa externa, se usa:

$$\Delta w_{ji} = \alpha \sum_k (\partial_{pk} w_{kj}) \bullet y_j(1 - y_j) y_{pi} \quad (1.2.4.14)$$

donde $\sum_k (\partial_{pk} w_{kj})$ representa la retropropagación del error.

2.5. ANALISIS DE SENSIBILIDAD

El análisis de sensibilidad se basa en medir el efecto observado en y_k del rendimiento, debido al cambio que se produce en x_i de la entrada. Así, el mayor efecto observado en el rendimiento, la mayor sensibilidad que nosotros podemos deducir estará presente en relación a la entrada. Entre varios acercamientos del análisis de sensibilidad se presenta a la matriz Jacobiano de sensibilidad como una de las metodologías importantes.

La matriz Jacobiano de sensibilidad: Consiste en que los elementos que constituyen la matriz de Jacobiano S , proporcionan analíticamente una medida de sensibilidad del rendimiento, a cambios que se producen en cada una de las variables de la entrada.

En la matriz de Jacobiano S del orden $N \times M$, cada fila representa una entrada en la red y cada columna representa un rendimiento de una red de computadoras, de tal

manera que el elemento S_{ik} de la matriz representa la sensibilidad del rendimiento k con respecto a la entrada i . Cada uno de los elementos de S_{ik} se obtiene calculando la derivada parcial de un y_k del rendimiento con respecto a un x_i de la entrada (Obispo, 1995). En este caso la derivada parcial representa una función subyacente entre x_i y y_k , de tal manera que para algunos valores fijados en ambas variables, el mayor en valor absoluto de S_{ik} , es el más importante en x_i respecto a y_k . La señal en S_{ik} indica, si el cambio observado en y_k está entrando en la misma dirección o no cuando el cambio se provocó en x_i . Desde que los modelos de entradas diferentes pueden generar diferentes valores, la sensibilidad necesita ser evaluada en todo el juego de entrenamiento. De esta manera, es útil obtener una serie de indicadores estadísticos como la media aritmética, desviación normal, cuadrado medio del error, valor mínimo y máximo de sensibilidad para obtener la factibilidad de la arquitectura.

1.3. MODELO DEL SISTEMA DE COMPETITIVIDAD EN LA CLASIFICACION DE LOS SUBSECTORES INDUSTRIALES

1.3.1. NIVEL DE INVESTIGACION

El estudio consiste en analizar el nivel de competitividad de las actividades económicas industriales o subsectores industriales (CIIUs) correspondiente al año 2000 mediante la aplicación de la técnica de redes neuronales.

En primer lugar, se trata de obtener un sistema capaz de determinar automáticamente si un subsector industrial es competitivo en función a siete indicadores económicos. Para ello nos apoyamos en la referencia [Félix Jiménez, Giovanna Aguilar y Javier Kapsoli ,1998], donde se estudia mediante técnicas estadísticas los indicadores de competitividad para la situación en concreto. En este estudio se desprende que de los múltiples indicadores que pueden definirse, resultan siete los más significativos en el momento de determinar una situación de competitividad, las cuales están relacionadas con la producción, inversión, productividad y comercio exterior.

1.3.2. NECESIDADES DEL SISTEMA

Para el desarrollo del sistema se debe identificar y desarrollar de forma concreta las especificaciones que debe cumplir el sistema [Von Bertalanffy, 2004]. Siendo necesario plantearse la cota de error que se desea alcanzar, el tipo de formulación que se va aplicar (predicción, clasificación, series temporales, ajuste funcional, procesado de señales, entre otras), la forma en que se dispondrán los datos, el tiempo de respuesta requerido, los equipos informáticos necesarios para su ejecución (a nivel de máquinas y de programas de simulación). Todas estas informaciones ayudarán a elegir un modelo de RNA que cumple con los requerimientos para su aplicación, así como la necesidad de trabajar con RNA a nivel de simulación, o bien de tarjeta aceleradora o circuito integrado específico entre otras.

1.3.3. SELECCION DEL MODELO DE RNA

El proceso de selección del modelo se realiza una vez especificado a detalle las características de nuestro problema, donde se elige un modelo de RNA con el que se debe comenzar a hacer las pruebas. En ese sentido, las arquitecturas de RNA más empleadas son las siguientes:

- a) **Perceptrón multicapa (MLP)** con aprendizaje *Backpropagation*, como caso de red de aprendizaje supervisado.
- b) **Mapas autoorganizados de Kohonen (SOFM)**, como red no supervisada.
- c) Otros modelos muy habituales en las aplicaciones prácticas son la RBF y el LVQ, y otros bastantes empleados son SVM, GRNN, ART y CNN.

Los modelos de redes neuronales son esencialmente, modelos de indicadores, los cuales no siempre presentan una clara relación económica. A pesar de ello, lo que se busca es minimizar el error de clasificación, eligiendo un modelo neuronal o arquitectura adecuada, de ello dependerá que sea una poderosa herramienta de análisis para su aplicación en el estudio [Del Brío y Sanz Molina *et al.*, 2002].

1.3.4. FUENTES DE RECOLECCION DE DATOS

Las fuentes de recolección de datos en el presente proyecto de investigación se obtuvieron específicamente de la institución pública encargada de manejar indicadores económicos y macroeconómicos bajo su ámbito de competencia del sector industrial y pesquero, como es el Ministerio de la Producción; siendo estos indicadores relacionados a la producción, comercio exterior, productividad e inversiones industriales obtenidos a partir de una encuesta anual que es realizado por dicha institución (Ver Anexo N°10).

Método de recolección de datos:

<i>Tipo de encuesta:</i>	cuantitativo y cualitativo
<i>Unidad Estadística:</i>	establecimiento manufacturero
<i>Periodicidad:</i>	anual
<i>Tipo de investigación:</i>	muestra dirigida a establecimientos grandes, medianas y pequeñas de cada grupo de CIIU.
<i>Cobertura:</i>	industria manufacturera peruana
<i>Representatividad:</i>	74 clases de la CIIU Rev.3 (cuatro dígitos) para total del país
<i>Tamaño de muestra:</i>	17 965 establecimientos manufactureros determinados por el INEI
<i>Número de informantes de la EEA año 2000:</i>	6 435 (1 054 representan a las grandes empresas, 1 525 medianas y 3856 pequeñas según valores de ventas netas)

Información que es consistenciada con las encuestas manufactureras mensuales dirigidas a las grandes empresas. Asimismo, se debe tener en cuenta que una empresa puede realizar una o varias actividades industriales.

La data obtenida como resultado del procesamiento de la encuesta, la misma que es empleada para el desarrollo del trabajo de investigación se presenta en el Anexo N°7.

1.3.5. SELECCION DE VARIABLES RELEVANTES

En la determinación de qué variables se deben emplear en el procesamiento de la información, es necesario conocer que muchas variables independientes implican una alta dimensión en el espacio de búsqueda, el cual puede conducir a un error de generalización elevada, pero en este caso por exceso de varianza en el modelo neuronal.

Para ello, una posibilidad más formal de seleccionar variables relevantes es hacer uso de las herramientas de la estadística, así como sus técnicas de construcción de modelos, ya que en ellas se analizan multicolinealidades de las variables independientes (posibles entradas de la RNA) y se mide la variabilidad de las variables dependientes (candidatos a ser las salidas de la RNA), quedándonos con aquellas variables independientes que más variabilidad producen sobre las dependientes.

Para el presente estudio, se contó con un total de 15 variables económicas y 73 subsectores industriales (observaciones), obtenidas como resultado del procesamiento de la encuesta, las cuales mediante los criterios de selección anteriormente mencionados se concluyó emplear solo siete variables económicas que son significativos en el análisis de competitividad. Antes de aplicar las técnicas estadísticas a las variables en estudio fueron transformadas en una misma unidad, con excepción de las unidades porcentuales, a fin de homogenizar la data y con ello obtener resultados coherentes.

1.3.6. MODELO DEL SISTEMA DE COMPETITIVIDAD DEL SECTOR INDUSTRIAL MANUFACTURERO

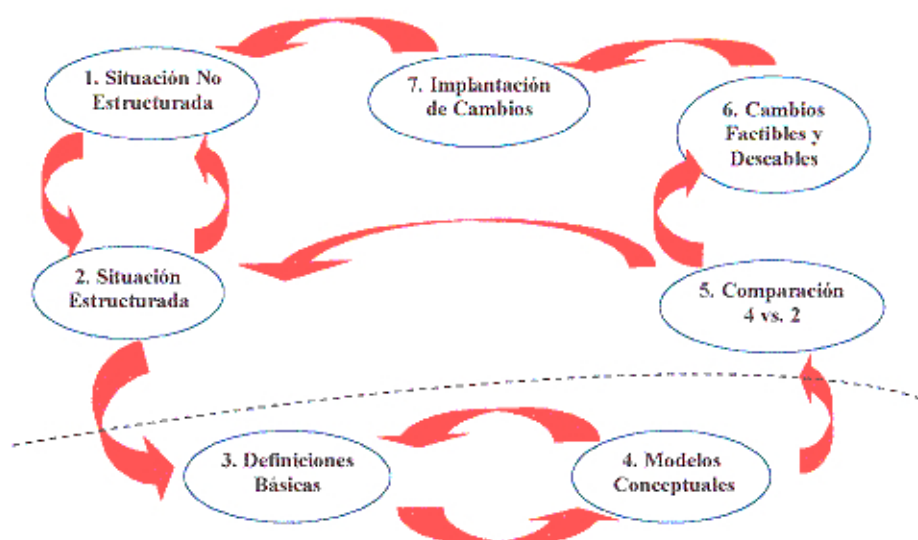
1.3.6.1. APLICACION DE LA METODOLOGIA DE SISTEMAS SUAVES

Fase de Conceptualización

La fase de conceptualización a través de la metodología de sistemas suaves con la aplicación de los siete estadios, nos permite utilizar un enfoque sistémico en los sistemas de la actividad humana para tratar de aliviar o mejorar las situaciones problemáticas [Checkand Peter, 1994].

Tal es el caso que para realizar el estudio y análisis de la competitividad del sector industrial manufacturero mediante la construcción del modelo de redes neuronales, fue necesario realizar un breve diagnóstico de las actividades industriales que conforman la industria y la contribución que en su conjunto éstas influyen sobre la actividad exportadora y productiva a nivel nacional. Sin embargo, el problema que surge es generar un modelo de competitividad para la Industria manufacturera que muestre el desempeño externo de las actividades industriales - CIUs, en función a factores determinantes con la orientación exportadora y productiva, bajo la restricción de obtener un indicador con enfoque interno.

ESTADIOS DE LA METODOLOGIA DE LOS SISTEMAS SUAVES



Estadio 1: Situación problemática no estructurada.

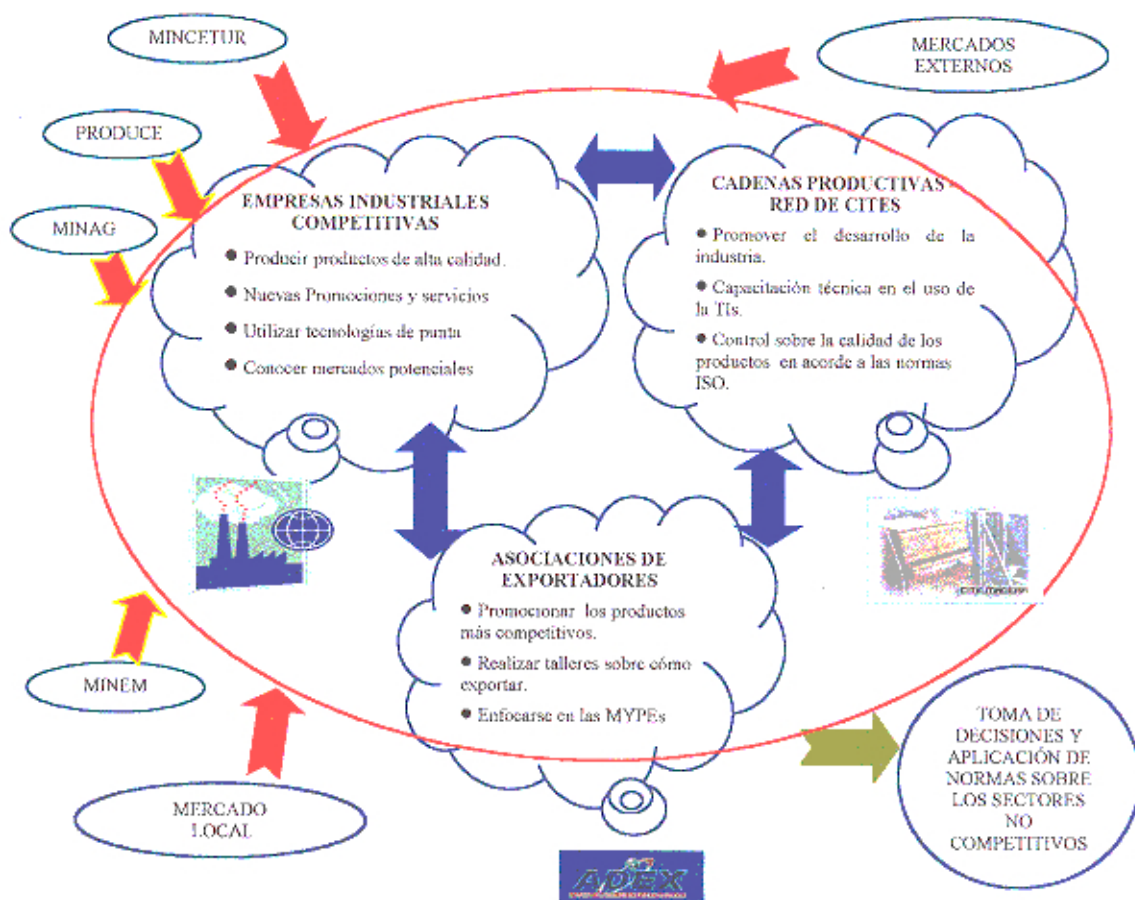
En esta etapa se observan acontecimientos que suceden en la situación problema, aún sin tener una idea clara de las interrelaciones de los elementos que la conforman.

De acuerdo a las opiniones y documentos de trabajo que se han desarrollado sobre la competitividad de la industria manufacturera, muchas de ellas carecen de un modelo matemático que expliquen los factores determinantes de la competitividad en el sector industrial. Por tanto, no es posible determinar el nivel

de competitividad de las actividades industriales, debido a esto se plantea de manera específica el problema: ¿Presenta la Industria Manufacturera una estructura competitiva externa?. Y como un problema específico se plantea: ¿Qué actividades económicas de la Industria Manufacturera orientan la mayor parte de su producción al mercado externo y/o interno?.

Estadio 2: Situación Problemática Estructurada

En esta etapa se concatenan los elementos que integran la situación problema, haciendo una descripción del pasado - presente y su consecuencia en el futuro, y recogiendo aspiraciones, intereses y necesidades del Sistema Contenedor del Problema. Se realiza a través del cuadro pictográfico.



Estadio 3: Definiciones raíz de sistemas pertinentes

La finalidad del tercer estadio es obtener las definiciones raíz partiendo de los sistemas pertinentes obtenidos del estadio dos.

Un sistema pertinente es un sistema de actividad humana, que el investigador usa en la metodología de sistemas suaves, nombra como candidato a generar discernimiento en estadios posteriores del estudio. Por cada sistema pertinente se formula una definición raíz, y se construye un modelo conceptual.

De acuerdo al contexto del sector industrial manufacturero se pretende construir un modelo de competitividad, el cual ha sido considerado como un sistema pertinente en la determinación de las actividades industriales competitivas y no competitivas. De tal manera, que se llevó a cabo la identificación del CATWOE [Peter Checkland, 1993]. Cada letra de esta palabra, identifica a cada uno de los elementos que intervienen en el sistema y que van a servir para la formulación de la definición raíz.

El significado de las letras de CATWOE se muestra a continuación:

C: Consumidores o Clientes del sistema. - Estos son las víctimas o beneficiarios de la transformación.

A: Actores. - Aquellos que harían la transformación.

T: Transformación.- La conversión de entrada en salida.

W: Weltanschauung.- La visión del mundo que hace a esta T significativa en contexto.

O: Dueño.- Aquellos que podrían detener T, el tomador de decisiones.

E: Environment.- Elementos fuera del sistema que este toma como dados.

Para el caso del sistema de competitividad del sector industrial se define:

C: Empresas industriales.

A: Empresas industriales, asociaciones de exportadores y cadenas productivas.

T: No evaluar el nivel de competitividad del Subsector Industrial →
Evaluar el nivel de competitividad del Subsector Industrial.

W: Empresas industriales con mayor penetración en los mercados externos.

O: Las grandes y medianas empresas industriales.

E: Mercados potenciales y consumidores locales, los organismos estatales que influyen en las medidas normativas y la tecnología.

Una vez identificados todos los elementos del CATWOE, se procede a declarar la definición raíz, que es la conjunción de estos elementos en una frase.

Una definición raíz expresa el propósito núcleo de un sistema de actividad con propósito definido. Dicho propósito núcleo siempre se expresa como un proceso de transformación en el cual alguna entidad la “entrada”, se cambia o transforma en una forma nueva de la misma entidad la “salida”.

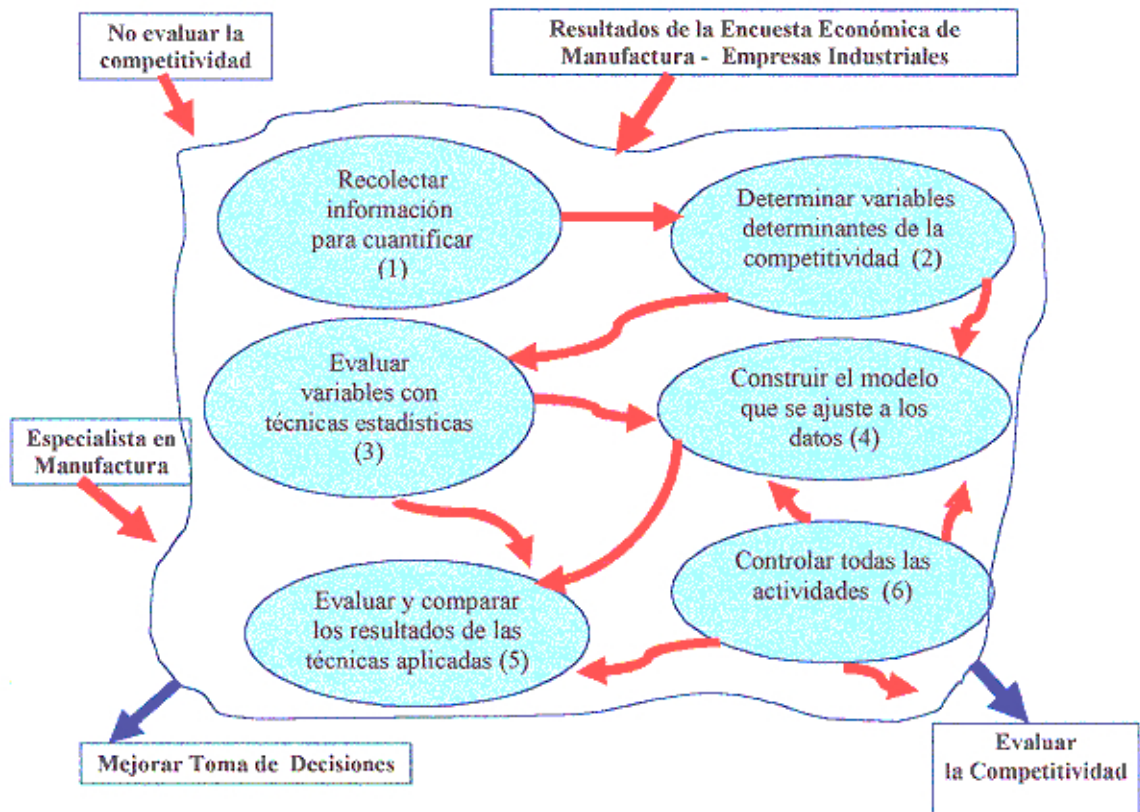
Una definición de raíz para la aplicación en estudio sería: Un sistema que explique los factores determinantes del nivel de competitividad en la industria manufacturera, a través de la construcción de un modelo matemático eficiente en el proceso de clasificación de un Subsector industrial como “competitivo” o “no competitivo”.

Estadio 4: Elaboración de modelos conceptuales

Los modelos conceptuales representan el “Cómo” se podría llevar a cabo el proceso de transformación planteado en la definición básica.

Este modelo consiste en un modelo operacional que identifica a los subsectores industriales competitivos y no competitivos mediante la aplicación de dos técnicas: redes neuronales y estadísticas multivariadas. La actividad central de este sistema operacional se basa en determinar un modelo clasificador de datos, eficiente y con un margen de error mínimo en el ajuste de los datos. Para esto se realiza la comparación de ambas técnicas, tanto de los indicadores de eficiencia, así como de los resultados obtenidos.

MODELO CONCEPTUAL DEL SISTEMA DE COMPETITIVIDAD



Estadio 5: Comparación del estadio 4 con el estadio 2

En esta etapa se compara el estadio 2 (cuadro pictográfico) con el estadio 4 (elaboración de modelos conceptuales).

El modelo conceptual del sistema de competitividad para la industria manufacturera requiere como entrada información de las variables determinantes para evaluar la competitividad, los cuales están relacionadas a la actividad productiva y exportadora, y reflejan el comportamiento registrado por las empresas industriales durante el periodo de estudio. Esta información, es también resultado de las medidas de desarrollo y promoción que han sido ejecutados para este sector, por los entes gubernamentales, tal como se aprecia en el cuadro pictórico su participación, tal vez no con mayor fuerza por lo que no ha sido posible impulsar la industria para todos los subsectores industriales por diversos factores ya sean económicos, políticos y sociales.

Por otro lado, no se tiene una identificación clara sobre el comportamiento de estas subsectores industriales y su nivel de competitividad, a pesar de la gran importancia que estas presentan y contribuyen con una mayor participación en la generación de divisas para el país. Asimismo, también se ha visto afectado por la competencia de mercados internacionales que ofrecen productos a menores precios, reduciendo de esta manera la oferta exportable del país.

Estadio 6: Cambios factibles y deseables

En esta etapa se detectan los cambios que son posibles llevar en la realidad.

Estadio 7: Implantación de cambios

Representa la implantación de los cambios detectados en la etapa anterior.

De los estadios 6 y 7 se resume lo más importante:

- ✓ Suministrar de información actualizada sobre la actividad productiva y exportadora de las empresas industriales.
- ✓ Determinar los subsectores no competitivos, a fin de aplicar medidas normativas para mejorar su actividad productiva y además su capacidad exportadora.
- ✓ Impulsar la industria con la apertura de nuevos mercados internacionales mediante negociaciones comerciales.
- ✓ Promover programas de consumo y promoción de productos.
- ✓ Identificar los mercados potenciales.

1.3.6.2. SISTEMA DE COMPETITIVIDAD DEL SECTOR INDUSTRIAL MANUFACTURERO

El Modelo de Sistemas del Sector Industrial Manufacturero nos permite visualizar que las principales necesidades de información del sector es evaluar el comportamiento de los subsectores industriales o actividades económicas que están comprendidas en dicho sector, a fin de analizar su situación productiva y competitiva en el mercado local y externo mediante un modelo construido en base a indicadores económicos de producción, productividad, inversiones y comercio exterior [Jiménez, Aguilar y Kapsoli, 1998].

La construcción del modelo en base a estos indicadores económicos generará al indicador de competitividad que a través de ello se determinará la competitividad en los subsectores industriales (CIIUs), del cual se inducirá la competitividad del Sector Industrial Manufacturero peruano en el periodo 2000.

El modelo de sistemas presenta como entrada, datos de los 73 subsectores industriales medidos a través de siete indicadores económicos: producción industrial, insumos, inversión fija, exportaciones, importaciones, stock de inversión extranjera directa y tasa de utilización de capacidad instalada. Las cuales son evaluados mediante un modelo de competitividad que genera índices con valor de 0 o 1. Siendo el modelo construido con una muestra de 30 CIIUs elegidos aleatoriamente y desarrollado en la etapa de aprendizaje; este último consiste en generar patrones que miden el nivel de competitividad.

Los datos de la salida muestra el estado de competitividad, con el cuál se va identificar si el subsector industrial en estudio es competitivo o no. Asimismo, el medio ambiente del sistema se restringe a las actividades del Sector Industrial Manufacturero peruano, ya que también hay actividades industriales pertenecientes a otros sectores económicos: Pesca, Agricultura, Minería y Servicios.

El modelo de sistemas de competitividad gráficamente se puede representar de la siguiente forma:



El modelo de competitividad que genera los índices se desarrolla en el siguiente capítulo 2.4.

CAPITULO II

DESARROLLO DEL PROCESO DE CLASIFICACION DE LAS ACTIVIDADES INDUSTRIALES MANUFACTURERAS

En el presente proyecto de investigación se desarrollan las técnicas de las redes neuronales artificiales, mediante la construcción de un modelo de retropropagación que permitirá la creación de un indicador de competitividad, el cual se utilizará en la clasificación de los subsectores industriales, identificando así, a las actividades industriales del sector manufacturero que han tenido un impacto positivo o negativo en su nivel competitividad explicado en el empleo de 7 indicadores económicos en estudio, relacionados a la producción, inversión, productividad y comercio exterior siendo evaluados en el período 2000, con información elaborada por el Ministerio de la Producción que se obtiene a partir de las Encuestas Económicas Anual Manufacturero realizada por dicha institución. De esta manera, los resultados que se obtienen permitirán determinar la oferta exportable de dichas actividades industriales al interior del sector. Asimismo, resulta significativo también identificar aquellos sectores que no han tenido una orientación exportable, posiblemente las empresas como unidades elementales de muestreo que realizan estas actividades orienten su producción al mercado interno o la mayoría de ellas se encuentren sin operar. Para realizar dicho análisis se procede a desarrollar los siguientes procedimientos:

2.1. PLANTEAMIENTO DEL PROBLEMA

El estudio consiste en el análisis de la competitividad de las actividades económicas industriales o subsectores industriales (CIIUs) en el año 2000 mediante la aplicación de redes neuronales.

Para ello se realiza un sistema capaz de determinar si un subsector industrial de la Manufactura Peruana es competitivo al interior del sector. El interés de este análisis radica en determinar e identificar los subsectores industriales que contribuyen de modo significativo en la generación de divisas en el sector manufacturero peruano y de los que no presentan competitividad. Es sobre estos resultados que se tomará medidas de política y decisiones para los subsectores no competitivos, a fin de brindarle apertura en el mercado local y externo mediante convenios o tratados de libre comercio. En el caso de las actividades industriales que presentan competitividad podrían aplicarse medidas políticas para mantener su nivel de crecimiento y aperturar nuevos mercados en otros continentes.

El método utilizado en los anteriores trabajos de investigación del sector se basan en la aplicación de técnicas estadísticas convencionales, a fin de que para obtener resultados aceptables o pocos confiables se requiere la intervención de un experto para realizar el ajuste de múltiples parámetros del programa.

2.2. REQUERIMIENTO DEL SISTEMA

El sistema ha desarrollarse debe proporcionar la identificación del estado de competitividad del subsector industrial, de forma automática y no supervisada, para cada una de los 73 subsectores industriales con las variables de entrada que se utilizan en este trabajo de investigación. Además, el sistema debe ser capaz de adaptarse automáticamente a los cambios que se observe en la industria (como la desagregación de subsectores industriales).

Dado que no existe un algoritmo que resuelva el problema con las condiciones de contorno expuestas, y teniendo en cuenta que las redes neuronales artificiales han demostrado conseguir buenos resultados en la clasificación de patrones, se experimentó con la aplicación de ésta técnica [Olson y Mossman, 2003].

2.3. DATOS DISPONIBLES Y CRITERIO DE SELECCION DE VARIABLES

Por un lado, la información recolectada de los indicadores económicos fue parte de la Encuesta Anual Industrial Manufacturero obtenido del Ministerio de la Producción. Por otro lado, se obtuvieron indicadores de comercio exterior de la Superintendencia Nacional de Administración Tributaria y el Instituto Nacional de Estadística e Informática para consistencia y verificación de los datos.

Para cuantificar la importancia de las variables a emplear en el estudio se decidió seguir dos estrategias: por un lado, se consultó a ingenieros industriales conocedores sobre el tema, quienes aportaban sus conocimientos y el fundamento para elegir los indicadores adecuados, y por el otro, se llevo a cabo diferentes análisis estadísticos sobre los datos (como estudio de correlaciones y análisis de componentes principales) llegando a resultados similares por ambas situaciones [Del Brío y Sanz Molina *et al.*, 2002].

La etapa de análisis estadístico realizado para la selección de variables significativas según el grado de asociación; se aplicó dos técnicas estadísticas como son: el análisis de correlación y el análisis de cluster ambos con el propósito de encontrar agrupaciones de variables que guardan una relación entre ellas. A continuación se desarrollan las dos técnicas empleadas para la selección de variables relacionadas al indicador de competitividad.

a) Análisis de Correlación

Esta técnica estadística permitió identificar y cuantificar la relación existente entre dos o más variables económicas, el criterio de seleccionar las variables con alto o bajo grado de asociación se representa por un valor o coeficiente que se interpreta así: si el valor es cercano a +1, se dice que la relación existente entre las variables es positiva; si el valor es cercano a -1, se dice que la relación entre ambas variables es inversa [Acuña *et al.*, 1999].

El indicador de grado de asociación existente entre dos o más variables X e Y es llamado coeficiente de correlación simple de Pearson, el cual se define a nivel muestral como:

r

$$\rho = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}, \quad -1 \leq \rho \leq 1$$

Donde:

n : representa el número de observaciones

X_i, Y_i : representa la variable en estudio

\bar{X}, \bar{Y} : representa el promedio muestral

Para el presente estudio se contó con 15 variables económicas y cada una con un total de $n = 73$ observaciones. El cálculo del coeficiente de correlación se realizó con cada par de variables, determinando así una matriz de coeficientes de correlación, tal como se muestra en el Cuadro N°1.

<u>Código</u>	<u>Variables</u>
1. VTPA	Valor Total de la Producción Anual (Producción Industrial)
2. VTC	Valor Total de Consumo (Insumo)
3. ION	Insumo de Origen Nacional
4. MPCN	Materia Prima Consumida Nacional
5. IOE	Insumos de Origen Extranjero
6. MPCE	Materias Primas Consumida Extranjero
7. VACIN	Valor Agregado Con Impuestos Netos
8. TB	Tributos
9. VTIA	Valor Total de la Inversión Anual en Activo Fijo (Inversión Fija)
10. FBK	Formación Bruta de Capital
11. TVENT	Total de Ventas
12. EXP	Exportaciones
13. IMP	Importaciones
14. SIED	Stock de Inversión Extranjera Directa
15. TUCI	Tasa de Utilización de la Capacidad Instalada

Cuadro N°1

Matriz de Correlación (Pearson)

VTC	VTPA	VTC	ION	MPCN	IOE	MPCE	VACIN	TB
VTC	0.982							
ION	0.991	0.980						
MPCN	0.964	0.953	0.976					
IOE	0.800	0.883	0.771	0.744				
MPCE	0.791	0.877	0.763	0.739	1.000			
VACIN	0.918	0.936	0.903	0.849	0.862	0.855		
TB	0.505	0.453	0.502	0.358	0.264	0.250	0.487	
VTIA	0.570	0.516	0.561	0.493	0.326	0.309	0.436	0.669
FBK	0.657	0.640	0.659	0.630	0.490	0.481	0.588	0.527
TVENT	0.993	0.993	0.986	0.954	0.847	0.839	0.939	0.487
EXP	0.590	0.626	0.631	0.610	0.510	0.504	0.575	0.405
IMP	0.335	0.407	0.319	0.295	0.547	0.545	0.430	0.070
SIED	0.458	0.506	0.449	0.343	0.555	0.549	0.566	0.348
TUCI	0.408	0.375	0.417	0.398	0.216	0.210	0.312	0.261
FBK	VTIA	FBK	TVENT	EXP	IMP	SIED		
FBK	0.829							
TVENT	0.531	0.632						
EXP	0.460	0.536	0.599					
IMP	0.098	0.215	0.391	0.314				
SIED	0.178	0.052	0.502	0.297	0.399			
TUCI	0.199	0.197	0.380	0.209	-0.132	0.228		

El Cuadro N°1 muestra los coeficientes de cada par de variables, el primer valor calculado de la matriz (0.982), este valor como esta más próximo a +1 indica una alta correlación positiva entre el Valor total de consumo y el Valor de producción. Bajo este criterio de interpretación para cada par de variable, se identificó a un grupo de variables con alto valor de asociación respecto a las demás variables como son: Producción Industrial, Insumo, Insumo de origen nacional, Materia prima de consumo nacional, Exportaciones y Total de ventas, es decir existe una buena relación lineal entre dichas variables.

Sin embargo, algunas de las variables como: Importación y Tasa de utilización de la capacidad instalada que presentan un grado de asociación bajo en relación con las demás variables, fue necesario tomarlos en cuenta para nuestro análisis y enfoque del estudio por la relación que tiene con el indicador de competitividad.

Como resultado de las agrupaciones se identificó tres grupos de variables con alto valor de asociación entre sí y su relación con los factores de competitividad: el primer grupo: Producción Industrial, Insumos, Inversión Fija y Tasa de utilización de la capacidad instalada; un segundo grupo: Insumos, Stock de Inversión extranjera directa e Inversión fija y un tercer grupo: Importaciones,

Insumos de origen extranjero y Tasa de utilización de la capacidad instalada, por lo que se concluye considerar siete indicadores económicos generado a partir de los grupos mencionados.

Por consiguiente, es importante conocer la asociación entre las variables para su selección, ya que pueden seleccionarse variables no significativas en relación con las que están correlacionadas entre sí. Esta técnica nos permite dar un sustento estadístico del criterio de selección de las variables, pero el analista es quién debe seleccionar las variables adecuadamente por su conocimiento sobre el tema.

Otra forma de identificar grupos de variables relacionadas entre sí, es gráficamente mediante el análisis de cluster donde se visualiza claramente las diferentes agrupaciones de variables.

b) Análisis de Cluster de Variables

El análisis de cluster de variables se desarrolla mediante el algoritmo de agrupación simple donde las entradas son distancias o similitudes entre los pares de observaciones [Acuña *et al.*, 1999]. Los grupos se forman de las entidades individuales juntándose los vecinos más cercanos, esto por la menor distancia o mayor similitud. La expresión para hallar la distancia entre dos observaciones y formar una matriz D esta dado por:

$$d(x, y) = \sqrt{(x - y)' A (x - y)}$$

siendo $A=S^{-1}$ y donde S contiene la muestra de variancias y covariancias.

En el proceso de obtener los clusters se selecciona inicialmente la menor distancia en $D=\{d_{ik}\}$, y se agrupa las correspondientes observaciones como U y V para obtener el cluster (UV). Posterior a ello, se obtiene la distancia entre (UV) y cualquier otro cluster W mediante la siguiente fórmula:

$$d_{(UV)W} = \min\{d_{UW}, d_{VW}\}$$

Donde las cantidades d_{UV} y d_{VW} son las distancias entre los mas cercanos vecinos de los clusters U y W y clusters V y W respectivamente.

Los resultados del algoritmo de agrupación simple puede ser graficado a través de un dendograma o diagrama de árbol, donde las ramas representarían los clusters.

Es a través de este análisis donde se visualiza las agrupaciones de las variables según el grado de similitud (Ver Gráfica N°1), el cual permitió corroborar los resultados obtenidos mediante el análisis de correlación. Los resultados estadísticos de esta prueba se muestran en el Anexo N°2, es a partir de ello que dan como resultado a tres clusters claramente identificados, ellos se muestran a continuación.

Partición Final

Cluster 1

- Valor Total de la Producción Anual (Producción Industrial)
- Valor Total de Consumo (Insumo)
- Insumo de Origen Nacional
- Materia Prima Consumida Nacional
- Insumos de Origen Extranjero
- Materia Prima Consumida Extranjero
- Valor Agregado Con Impuestos Netos
- Total de Ventas

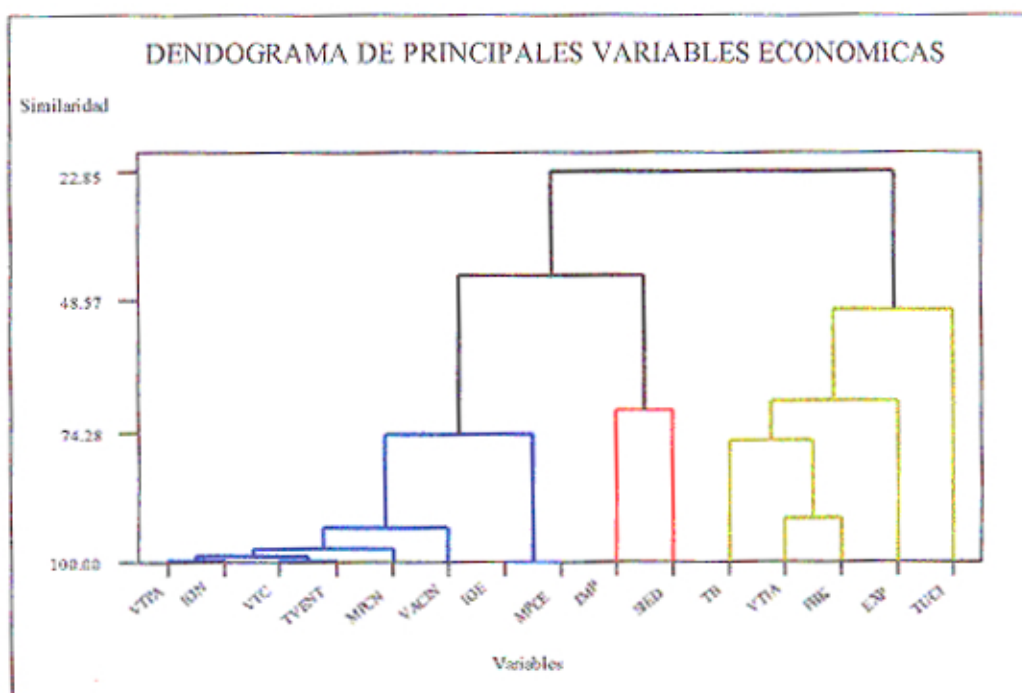
Cluster 2

- Tributos
- Valor Total de la Inversión Anual en Activo Fijo (Inversión fija)
- Formación Bruta de Capital
- Exportaciones
- Tasa de Utilización de la Capacidad Instalada

Cluster 3

- Importaciones
- Stock de Inversión Extranjera Directa

Gráfica N°1:



A partir de ésta clasificación en clusters se decidió elegir de cada agrupación a las variables que son indicadores esenciales en la competitividad del sector industrial manufacturero, determinándose así a los nuevos cluster:

Cluster 1

- Valor Total de la Producción Anual (Producción Industrial)
- Valor Total de Consumo (Insumo)

Cluster 2

- Valor Total de la Inversión Anual en Activo Fijo (Inversión fija)
- Exportaciones
- Tasa de Utilización de la Capacidad Instalada

Cluster 3

- Importaciones
- Stock de Inversión Extranjera Directa

Con el resultado obtenido mediante la aplicación de estos dos análisis estadísticos y empleando un criterio cualitativo de conocimiento con respecto a la identificación de variables económicas significativas para el estudio de la competitividad del sector industrial manufacturero, se concluye que de las 15 principales variables analizadas, siete son las permitieron construir el indicador de competitividad, debido a que estas son significativas entre sí, por el grado de correlación existente, tal como se ha demostrado mediante la aplicación de éstas dos técnicas estadísticas de inferencia.

Por tanto, las siete variables económicas a considerarse en el estudio se presentan en la siguiente tabla.

Tabla N°1: Definición de los indicadores utilizados en el estado de la competitividad del sector industrial manufacturero.

- X1: Producción Industrial (Miles de Nuevos Soles)
- X2: Insumos (Miles de Nuevos Soles)
- X3: Inversión Fija (Miles de Nuevos Soles)
- X4: Exportaciones (Miles de US\$)
- X5: Importaciones (Miles de US\$)
- X6: Stock de Inversión Extranjera Directa (Miles de US\$)
- X7: Tasa de Utilización de la Capacidad Instalada (%)

Estas variables miden las características propias de cada una de las 73 actividades industriales para determinar la competitividad de los mismos, y a ello se debe agregar la variable de control que indica la categoría en la cual se encuentra clasificada la actividad industrial [Mohd, 2004]. En la construcción del modelo las variables se definen como:

Variable dependiente o Control (Z_i)

Indicador de competitividad relativa: representa a un indicador de ventajas comparativas reveladas utilizado por la ONUDI (1985) [Comisión económica para América latina, 2000]. Este indicador muestra el desempeño externo de las

actividades industriales - CIIUs en materia comercial, y se construye en base a las exportaciones y/o importaciones de las actividades desagregadas a cuatro dígitos del CIIU bajo la restricción de obtener un indicador con enfoque interno.

La cual es expresado de la siguiente forma:

$$\text{Participación del Mercado} = \frac{X_{ij}}{X_j} * 100$$

Donde:

X_{ij} : Exportaciones con destino hacia los países del mundo de la actividad i registrado por el Sector j (Manufactura)

X_j : Exportaciones totales del Sector j (Manufactura) con destino hacia los países del mundo.

Variables Independientes (X_{iv})

- *Producción Industrial*: Se refiere a la cuantificación de la producción total de los establecimientos: artículos terminados para la venta, transferir y elaborada por terceros.

Valor Total de producción = Precio unitario de venta * Cantidad total
producida

- *Insumos*: Son los insumos de origen nacional y extranjero (materia prima) utilizados en el proceso productivo para la producción de bienes y servicios.

Insumos de origen nacional

- Materia prima consumida
- Combustibles y lubricantes consumidos
- Materiales auxiliares, envases y embalajes
- Repuestos y accesorios consumidos
- Energía eléctrica comprada
- Total de pagos por servicios industriales y otros
- Pagos por trabajos de carácter industrial
- Otros gastos de establecimiento

- Deducciones de impuestos a los bienes y servicios

Insumos de origen extranjero

- Materias primas consumidas
 - Combustibles y lubricantes consumidos
 - Materiales auxiliares, envases y embalajes
 - Repuestos y accesorios
- *Valor Total de la Inversión Anual en Activo Fijo (Inversión fija):* Representa los saldos finales de activos fijos al 31 de diciembre del año en ejecución, el cual puede ser expresado de la siguiente forma:

$$\text{Inversión Fija} = \text{Saldo inicial de activo fijo al 1ro de enero del año 2000} + \text{Compra de bienes (nuevos o usados)} - \text{Ventas y/o retiros de activos fijos al 31 de diciembre del año 2000}$$

- *Exportaciones:* representa la venta de productos nacionales (bienes y servicios) a un mercado extranjero.
- *Importaciones:* representa la compra de productos (bienes y servicios) a un mercado extranjero.
- *Stock de Inversión Extranjera Directa:* Están referidas a los distintos tipos de aporte al capital social (incluyen reducciones y transferencias de participación) en las empresas establecidas en el país, que son inversiones efectivamente realizadas y no corresponden a proyectos de inversión, flujos por préstamos, ni la valorización de mercancías u otros activos que no estén destinados al capital de la empresa local, que son considerados como inversión por otras fuentes informativas.
- *Tasa de Utilización de la Capacidad Instalada:* Existencia de bienes de capital disponibles para el proceso productivo, su plena utilización define la producción potencial (máxima) de una empresa.

$$TUCI = \frac{\text{Volumen de producción en el mes}}{\text{Volumen máximo de producción mensual}} * 100$$

Se tiene como única restricción la disponibilidad y combinación de equipos, para las diversas líneas de productos que fabrica el establecimiento, alternada o paralelamente.

2.4. ELECCION DEL MODELO

Antes de construir el modelo se realizó la consistencia de la data, con el propósito de eliminar los subsectores no significativos (valores de nulos en algunas variables), así como la significancia de las variables, que en este estudio se desprende de múltiples indicadores que pueden definirse a partir de las encuestas económicas anual de manufactura, de las cuales siete variables económicas fueron determinadas como significativas para la creación del indicador de competitividad basado en la utilización de técnicas estadísticas.

Asimismo, la construcción del modelo neuronal se desarrolló en base a la selección de estas siete variables relacionadas a la producción, comercio exterior, productividad e inversiones, que en su conjunto y por la relación que existe entre ellas permitió obtener un indicador de competitividad, el cual representa a la variable dependiente o funcional del modelo.

Para la elección del modelo a desarrollarse se optó por emplearse la arquitectura más utilizada de los modelos de redes neuronales artificiales en la clasificación de patrones como es el perceptrón multicapa entrenado mediante el algoritmo *backpropagation* (BP), ya que este modelo clasifica patrones con un alto valor de porcentaje, minimizando la función del cuadrado medio del error que hay entre la salida real y la salida deseada de la red [Shachmurove y Witkowska, 2003].

La representación del modelo neuronal de un perceptrón multicapa con una capa oculta y neuronas de salida lineal queda expresado de la siguiente manera:

$$z_k = \sum_j w_{kj} y_j - \theta'_k = \sum_j w_{kj} f\left(\sum_j w_{ji} x_i - \theta_j\right) - \theta'_k$$

Siendo la función $f(\cdot)$ de tipo sigmoideo:

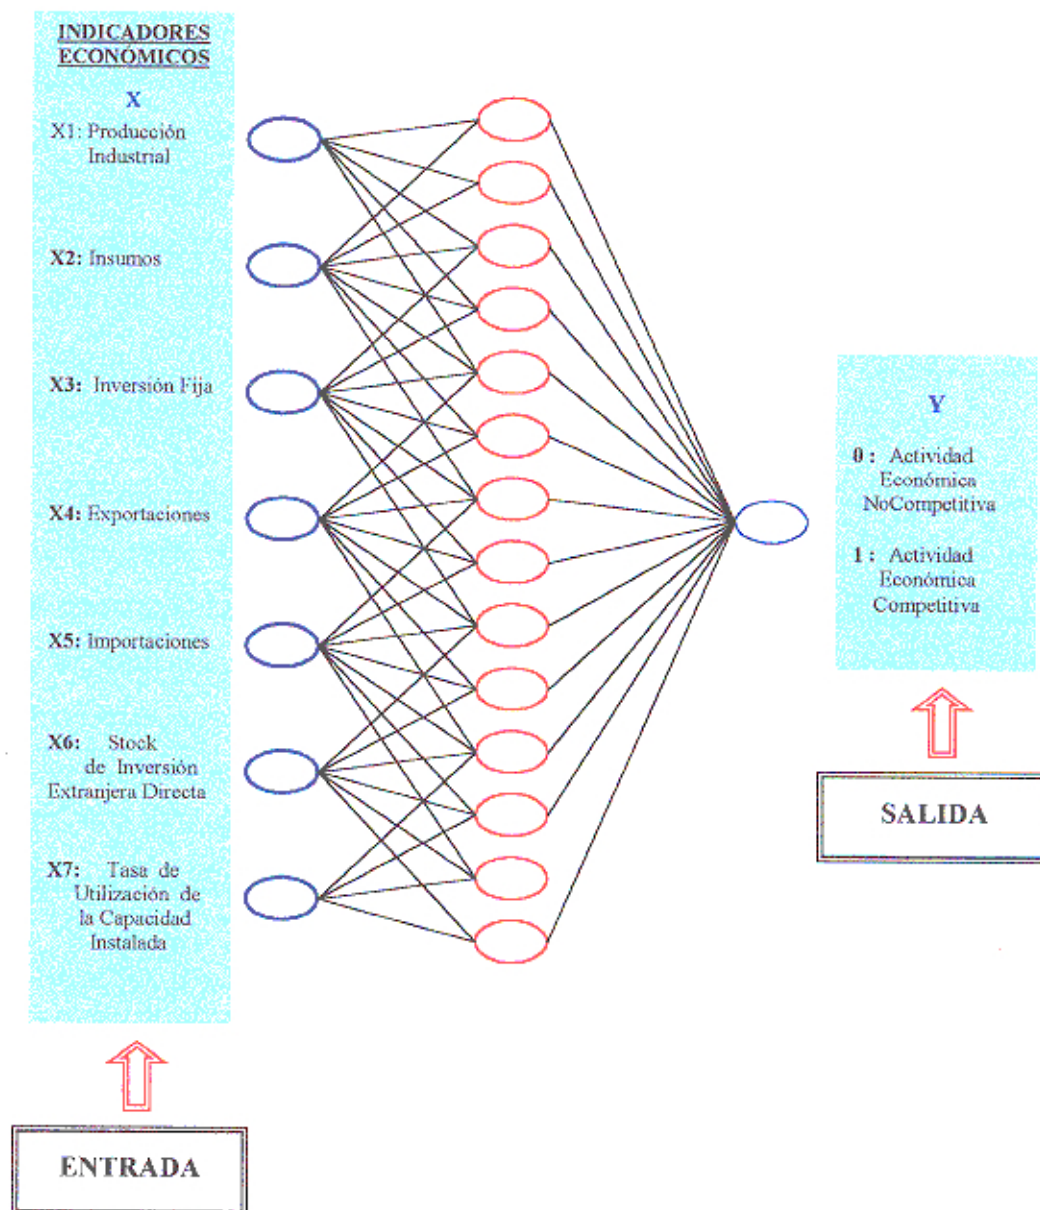
$$f(x) = \frac{1}{1 + e^{-x}} \text{ , con salidas en el intervalo } [0,+1]$$

Se denomina x_i a las entradas de la red, y_j a las salidas de la capa oculta y z_k a las de la capa final (globales de la red). Por otro lado, w_{ij} representa a los pesos de la capa oculta y θ_j sus umbrales, asimismo, w'_{kj} representa los pesos de la capa de salida y θ'_k sus umbrales [Del Brío y Sanz *et al.*, 2000].

En su proceso de desarrollo de esta arquitectura basada en el algoritmo BP se empleó a siete indicadores económicos que representan las entradas y una sola neurona de salida que nos indica un “1” si el subsector industrial es competitivo, y un “0” si no es competitivo (u orienta su producción al mercado interno), quedando solo en determinar el número más adecuado de neuronas ocultas, la misma que se obtuvo mediante el entrenamiento del modelo neuronal con una muestra de 30 subsectores industriales (patrones), un total de 14 neuronas ocultas.

La representación gráfica del modelo neuronal con sus entradas, salidas y capa oculta se muestra en la siguiente figura.

Gráfica N°2: Arquitectura de Perceptrón Multicapa 7-14-1 empleado para la determinación de competitividad (7 indicadores económicos de entradas, y una única neurona de salida 1 o 0, indicando competitividad y no competitividad)



El modelo neuronal definido determina la situación competitiva de las actividades industriales, identificando así aquellos subsectores competitivos y no competitivos. Es sobre este último donde se pretende aplicar medidas políticas, normativas y realizar convenios o negociaciones internacionales a fin de generar nuevos mercados e incrementar así nuestra oferta exportable en beneficio de mejorar el nivel de competitividad de estos subsectores.

2.5. ELECCION DE LOS CONJUNTOS DE APRENDIZAJE Y TEST

En la clasificación de los subsectores industriales se emplearon a 30 subsectores aleatorios para el aprendizaje, las cuales el 100% presentaron una clasificación correcta, así el error de clasificación en validación cruzada es nulo. Tras una serie de pruebas de entrenamiento de la red, se obtuvo un número de neuronas ocultas adecuado entre 10 y 16 con los que se obtuvieron buenos resultados. Así, finalmente nos quedamos con 14 neuronas ocultas representándose en una arquitectura 7-14-1.

Se observa que con una arquitectura 7-14-1 se tiene un total de 127 parámetros (entre pesos y umbrales) con lo que la regla $p=10w$ nos indicaría que se necesitarían aproximadamente 1 270 ejemplos de CIUs competitivos y no competitivos para entrenar esta red adecuadamente. Obviamente en el sector industrial manufacturero no se cuenta con tantos subsectores industriales, y se dispone de un total de 73 CIUs (ejemplos). Por lo que esta arquitectura fácilmente podría incurrir en sobreaprendizaje, por ello se decidió realizar un entrenamiento con validación cruzada [Del Brío y Sanz Molina *et al.*, 2002].

2.6. PREPROCESAMIENTO

En esta etapa cada proceso se desarrolló de manera independiente, tanto la prueba de entrenamiento como la conjunta. De esta forma, se empleó 30 subsectores industriales para el aprendizaje y 43 subsectores para la validación cruzada, mientras que en la prueba conjunta se empleó a los 73 subsectores industriales, una vez que la red ha sido entrenada.

La data de entrada se uniformizó para no variar el rango de todas las entradas, asimismo, el preprocesamiento también incluía potenciar ciertas variables que se sabía que deberían tener un papel relevante en la clasificación, a fin de identificar a los subsectores industriales competitivos que posteriormente fueron utilizados como referencia para la salida, con lo cual el modelo sería supervisado.

En este proceso, es vital la capacidad de aprendizaje que tiene la red cerebral. Si una serie de condiciones generan un resultado no aceptable para el usuario, las siguientes ocasiones en que estas circunstancias ocurran, es necesario tomar las precauciones necesarias a fin de minimizar el resultado nocivo.

Tabla N°2: Relación de los Subsectores Industriales (CIUs) empleadas en el estudio, los CIUs del 1 al 24 no fueron competitivos en el año 2000. Los subsectores industriales del 66 al 73 son los que presentaron alto índice de competitividad.

Id	CIU	Subsector Industrial	Id	CIU	Subsector Industrial
1	1600	Productos de tabaco	38	3410	Vehículos automotores
2	2731	Fundición de hierro y acero	39	1532	Almidones y derivados del almidón
3	2732	Fundición de metales no ferrosos	40	1541	Productos de panadería
4	1552	Elaboración de vinos	41	2919	Otros tipos maquinarias de uso general
5	3592	Bicicletas y sillones de ruedas	42	2893	Artículos de cuchillería y ferretería
6	3591	Motocicletas	43	2610	Vidrio y productos de vidrio
7	1554	Bebidas no alcohólicas, aguas minerales	44	2699	Otros productos minerales no metálicos n.e.p.
8	1542	Refinerías de azúcar	45	2811	Productos metálicos uso estructural
9	3420	Carrocerías para vehículos automotores, remolques y semiremolques	46	3110	Motores, generadores y transformadores eléctricos
10	1911	Cartido y adobo de cueros	47	2924	Maquinaria para minas, canteras y construcción
11	2695	Artículos de hormigón, cemento y yeso	48	2221	Actividades de impresión
12	2693	Productos de arcilla y cerámica no refractaria para uso estructural	49	2413	Plásticos en formas primarias y de caucho sintético
13	2911	Mótores y turbinas, excepto motores para aeronaves, vehículos automotores y motocicletas	50	1513	Elaborados de frutas, legumbres y hortalizas
14	2010	Aserrado, asepillado mader	51	2109	Artículos de papel y cartón
15	2691	Productos de cerámica no refractaria para uso no estructural	52	3699	Otras industrias manufactureras n.e.p.
16	2212	Periódicos, revistas y publico periódicas	53	2021	Hojas de madera para enchapado, tableros contrachapados, laminados, de partículas
17	2412	Abono y compuesto de nitrógeno	54	1549	Otros productos alimenticios n.e.p.
18	1723	Cuerdas, cordales, bramantes y redes	55	1514	Aceites y grasas, vegetal y animal
19	3610	Muebles	56	1533	Alimentos preparados para animales
20	2694	Cemento, cal y yeso	57	3130	Iluminación y cables aislados
21	1544	Macarrones, fideos y farfallecos	58	1730	Tejidos y artículos de punto y ganachillo
22	3120	Aparatos de distribución y control de la energía eléctrica	59	1543	Elaboración de queso, chocolate y confitería
23	2422	Pinturas, barnices y productos similares	60	2101	Pasta de madera, papel y cartón
24	3312	Instrumentos y aparatos para medir y otros afines, excepto de control de procesos industriales	61	3429	Productos químicos n.e.p.
25	2930	Aparatos de uso doméstico n.e.p.	62	1810	Prendas de vestir, excepto prendas de piel
26	3691	Joyas y artículos conexos	63	2899	Otros productos de metal n.e.p.
27	1553	Bebidas malteadas y de malta	64	2423	Productos farmacéuticos, botánicos
28	3430	Partes, piezas y accesorios para vehículos automotores y sus motores	65	2511	Cubiertas y cámaras de caucho
29	3140	Acumuladores, pilas y baterías primarias	66	2430	Fibras manufacturadas
30	1520	Productos lácteos	67	2710	Industrias básicas de hierro y acero
31	2912	Bombas, compres, grifos, válvulas	68	2411	Sustancias químicas básicas
32	2421	Plaguicidas y otros químicos de uso agropecuario	69	2320	Productos de refinación del petróleo
33	1920	Calzado	70	2424	Jabones, detergentes, productos de limpieza y tinteador
34	1531	Productos de molinería	71	2520	Productos de plástico
35	1551	Destilación rectificación, mezcla de bebidas alcohólicas	72	1711	Hilatura de fibras textiles, tejidos
36	2102	Papel, cartón ondulado y de envases de papel y cartón	73	2720	Metales preciosos y no ferrosos, primarios
37	1511	Cerve y productos cárnicos			

2.7. PROCESO DE ENTRENAMIENTO

Se comenzó con la estrategia de realizar simulaciones de arquitecturas con un número reducido de neuronas ocultas (ninguno, dos, cuatros,..) hasta aumentar su número progresivamente, a fin de alcanzar el número de capas ocultas adecuada.

En el entrenamiento, la red aprende la asociación de cada grupo de 7 indicadores económicos con el 0 o el 1 que los califica; con un número suficiente de patrones de entrenamiento. El perceptrón multicapa, generalizando los datos aprendidos, deberá encontrar la ley de competitividad subyacente (que se desconocía).

El entrenamiento se realizó mediante BP; el proceso iterativo ejecutado sobre un ordenador empleó típicamente del orden de 5 minutos. Realizando un estudio exhaustivo de la eficiencia del sistema neuronal mediante técnicas de *bootstrap* o dejar-uno-fuera, se encontró que el perceptrón multicapa propuesto entrenado con BP es capaz de determinar correctamente la situación del estado de competitividad en 100% de las ocasiones.

También se empleó el método de validación cruzada como criterio de parada del proceso de entrenamiento hasta minimizar el error de clasificación. Como medida del error se utilizó el error cuadrático medio (CME) promediado para todos los patrones y las salidas.

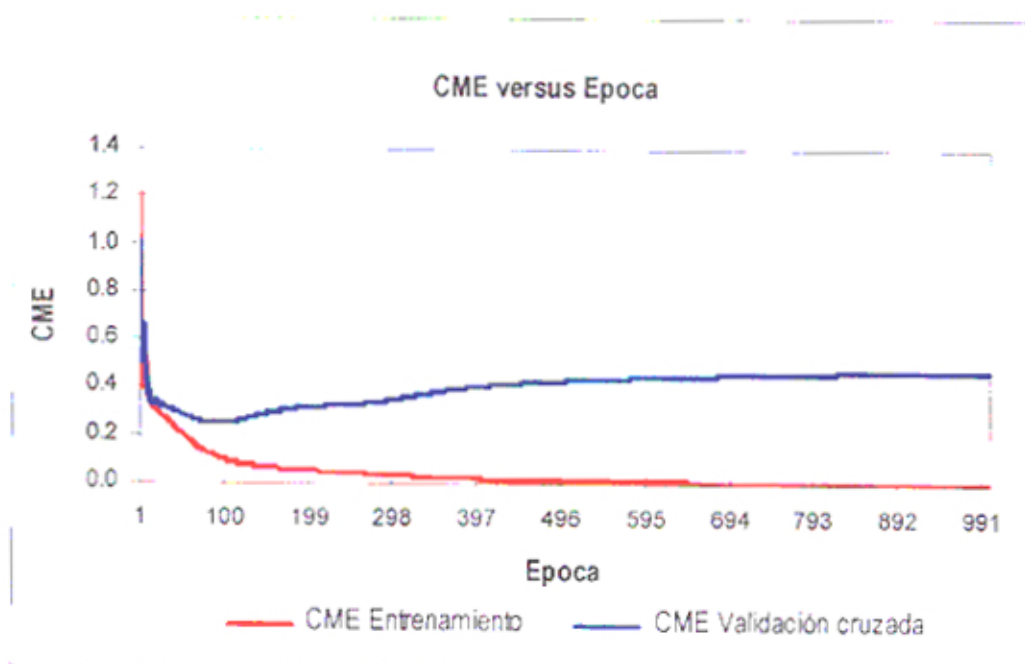
2.8. EVALUACION DE RESULTADOS

Los resultados que se obtuvieron en conjunto eran buenos, consiguiendo una clasificación de los subsectores industriales competitivos con una precisión al 100%, y alcanzando un error de entrenamiento alrededor de uno. De esta manera, con el sistema neuronal construido y cada uno de los siete indicadores económicos del sector industrial manufacturero, podremos establecer su nivel de competitividad sólo con alimentar con ellos la red y observar la salida: cuánto más próxima sea la salida al valor de 1.0 en mejor situación se encontrará el subsector, mientras más cercano a 0.0 se situé, será más crítico. Es importante mencionar que en las redes neuronales, a pesar que el proceso de entrenamiento

puede ser lento, la respuesta de la red una vez entrenado puede considerarse en muchas ocasiones instantáneas a efectos prácticos.

Análisis de la Gráfica N°3: Presenta el comportamiento del error según el número de épocas elegidas, como se puede apreciar el CME de entrenamiento tiende casi a cero (0.0023) cuando se incrementa el número de épocas. Sin embargo, el CME de validación cruzada aumenta hasta llegar a un punto estacionario con intervalo de error (0.2468, 0.4758). Por lo que se puede decir que el modelo neuronal en ese punto es óptimo.

Gráfica N°3:



Red Optimo	Entrenamiento	Validación Cruzada
Nº Epocas	1000	95
Mínimo CME	0.0023	0.2468
Final CME	0.0023	0.4758

El rendimiento del modelo neuronal, presentó un porcentaje de clasificación de 100%, con un CME de 0.2, valor que es bajo e indica menor variabilidad presente

en el modelo generado y por lo que se puede afirmar que el modelo neuronal se ajusta a los datos en estudio.

Tabla N°3:

Output / Desired	CIU
Subsectores Industriales	73

Rendimiento	Composición
Cuadrado Medio del Error (CME)	0.2
Cuadrado Medio del Error Normalizado	0.9
Error Medio Absoluto MAE	0.3
Error Mínimo Absoluto	0.0
Error Máximo Absoluto	1.0
Coefficiente de Correlación Lineal (r)	0.5
Porcentaje de Clasificación Correcto	100.0

Resultados obtenidos al aplicar el Modelo de Perceptrón Multicapa:

- Como resultado de aplicar la metodología de las RNAs en el proceso de clasificación sobre los 73 Subsectores Industriales; 35 subsectores industriales resultaron ser competitivos explicándose en que estos orientan su producción en un mayor volumen al mercado externo y local. Mientras que los 38 subsectores restantes se clasificaron como no competitivos, notándose que un grupo de estos abastecen todo o lo poco que producen al mercado interno y otros se encuentran estancados.
- De los 49 CIUs categorizados inicialmente como competitivos, utilizando el modelo neuronal se concluyó que solo 30 de estos son realmente competitivos, a estos se adicionan 15 subsectores del otro grupo que fueron inicialmente categorizados como no competitivos, lo que haría un total de 35 subsectores competitivos.
- De los 24 CIUs categorizados inicialmente como no competitivos, utilizando el modelo neuronal se concluyó que solo 9 de estos no son realmente competitivos, a estos se adicionan 29 subsectores del otro grupo que fueron inicialmente categorizados como competitivos, lo que haría un total de 38 subsectores no competitivos.

Identificación y clasificación de las actividades industriales (CIUs) según su nivel de competitividad mediante la aplicación del modelo de redes neuronales [Comisión Económica para América Latina, 2000].

Altamente Competitivos:

Constituido por actividades industriales que están ganando participación en el mercado local y que están ofertando productos dinámicos, es decir de mayor demanda en el mercado externo (ver Tabla N°4).

Las actividades industriales que lideran en este grupo se presentan a la Industria de refinación de petróleo, Plásticos en formas primarias y de caucho sintético, Productos químicos, Pasta de madera, Papel y cartón, y Vehículos automotores, debido a la mayor demanda del mercado internacional y por el consumo masivo en el mercado local. En el caso de la Industria de refinación de petróleo se debería a la importación de insumos para la producción y exportación al mercado externo, dado a que este sector cuenta con mayor inversión extranjera.

Tabla N°4:

CIU	DESCRIPCION	INDICE DE COMPETITIVIDAD
2320	Productos de refinación del petróleo	1,000
2413	Plásticos en formas primarias y de caucho sintético	0,996
2429	Productos químicos n.c.p.	0,991
2101	Pasta de madera, papel y cartón	0,987
3410	Vehiculos automotores	0,985
2423	Productos farmacéuticos, botánicos	0,984
2411	Sustancias químicas básicas	0,970
2710	Industrias básicas de hierro y acero	0,952
3430	Partes, piezas y accesorios para vehículos automotores y sus motores	0,933
1810	Prendas de vestir, excepto prendas de piel	0,927
2899	Otros productos de metal n.c.p.	0,901
2811	Productos metálicos uso estructural	0,878
2912	Bombas, compresores, grifos, válvulas	0,855
1920	Calzado	0,850
1531	Productos de molinería	0,826
2720	Metales preciosos y no ferrosos, primarios	0,811
2520	Productos de plástico	0,793
1549	Otros productos alimenticios n.c.p.	0,776
1513	Elaborados de frutas, legumbres y hortalizas	0,772

Competitivos:

Conformado por actividades industriales que están ganando participación en el mercado local, pero no están ofertando productos dinámicos (ver Tabla N°5).

Las actividades industriales que destacan en este grupo se tiene a la Industria de Tejidos y artículos de punto y ganchillo, Joyas y artículos conexos, Elaboración de cacao y chocolate y Hoja de madera para enchapado, debido a la mayor demanda interna, particularmente por el consumo privado, y por las mayores expectativas de incrementar su participación en el mercado exterior. En el caso de Otras industrias manufactureras n.c.p, su competitividad se debe a la mayor producción para el abastecimiento del mercado local y en menor cuantía hacia el mercado internacional.

Tabla N°5:

CIU	DESCRIPCION	INDICE DE COMPETITIVIDAD
1730	Tejidos y artículos de punto y ganchillo	0,713
3691	Joyas y artículos conexos	0,712
1543	Elaboración de cacao, chocolate y confitería	0,690
2021	Hojas de madera para enchapado, tableros contrachapados, laminados de partículas	0,687
1552	Elaboración de vinos	0,676
2924	Maquinaria para minas, canteras y construcción	0,667
2102	Papel, cartón ondulado y de envases de papel y cartón	0,650
2421	Plaguicidas y otros químicos de uso agropecuario	0,644
3699	Otras industrias manufactureras n.c.p.	0,642
2732	Fundición de metales no ferrosos	0,636
2610	Vidrio y productos de vidrio	0,629
2695	Artículos de hormigón, cemento y yeso	0,604
2893	Artículos de cuchillería y ferretería	0,598
3610	Muebles	0,581
3110	Motores, generadores y transformadores eléctricos	0,562
2422	Pinturas, barnices y productos similares	0,508

Oportunidades Perdidas:

Constituido por actividades industriales que están ofertando productos dinámicos pero que no están ganando participación en el mercado local (ver Tabla N°6).

Las principales actividades industriales que encuentran este grupo se tiene a Otros equipos de maquinarias de uso general, Cubiertas y cámaras de caucho, Aceites y grasas, vegetal y animal, Jabones, detergentes, productos de limpieza y tocador, Abonos y compuestos de nitrógeno, asociado a la mayor importación de productos, lo que se vería afectado en la producción interna. En el caso de la industria de Otros equipos de maquinarias de uso general, la pérdida de su competitividad radicaría en la mayor capacidad ociosa de sus establecimientos y mayor importación de maquinarias por las rebajas arancelarias.

Tabla N°6:

CIU	DESCRIPCION	INDICE DE COMPETITIVIDAD
2919	Otros tipos maquinarias de uso general	0,491
2511	Cubiertas y cámaras de caucho	0,425
1514	Aceites y grasas, vegetal y animal	0,397
2424	Jabones, detergentes, productos de limpieza y tocador	0,393
2412	Abono y compuestos de nitrógeno	0,389
2109	Artículos de papel y cartón	0,369
1551	Destilación, rectificación y mezcla de bebidas alcohólicas	0,365
1533	Alimentos preparados para animales	0,284
3120	Aparatos de distribución y control de la energía eléctrica	0,281
1532	Almidones y derivados del almidón	0,281
3140	Acumuladores, pilas y baterías primarias	0,262
2930	Aparatos de uso doméstico n.c.p.	0,226
1911	Curtido y adobo de cueros	0,212
3130	Hilos y cables aislados	0,205
2221	Actividades de impresión	0,202
2911	Motores y turbinas, excepto motores para aeronaves, vehículos automotores y motocicletas	0,179
2699	Otros productos minerales no metálicos n.c.p.	0,174
2430	Fibras manufacturadas	0,157
1511	Carne y productos cárnicos	0,150
1542	Refinerías de azúcar	0,149
1541	Productos de panadería	0,128
2010	Aserrado, acepilladura de madera	0,125
1553	Bebidas malteadas y de malta	0,118

Retroceso:

Conformado por las actividades industriales que no presentan expectativas en el mercado mundial porque no ganan mercado y no venden productos dinámicos (ver Tabla N°7).

Las actividades industriales que destacan en este grupo se presentan a Instrumentos y aparatos de medición, Cuerdas, cordeles, bramantes y redes, Motocicletas, Productos lácteos y Periódicos, revistas y publicaciones periódicas, se debería a la menor producción y orientación hacia el mercado externo. En el caso de la industria de Instrumentos y aparatos de medición se vería afectada por la menor demanda, lo que implicaría reducir su nivel de producción.

Tabla N°7:

CIU	DESCRIPCION	INDICE DE COMPETITIVIDAD
3312	Instrumentos y aparatos para medir y otros afines, excepto de control de procesos industriales	0,098
1723	Cuerdas, cordeles, bramantes y redes	0,098
3591	Motocicletas	0,094
1520	Productos lácteos	0,090
2212	Periódicos, revistas y publicaciones periódicas	0,083
2694	Cemento, cal y yeso	0,079
2691	Productos de cerámica no refractaria para uso no estructural	0,079
1600	Productos de tabaco	0,071
2731	Fundición de hierro y acero	0,063
2693	Productos de arcilla y cerámica no refractaria para uso estructural	0,062
3420	Carrocerías para vehículos automotores, remolques y semirremolques	0,047
3592	Bicicletas y sillones de ruedas	0,045
1544	Macarrones, fideos y farináceos	0,019
1554	Bebidas no alcohólicas, aguas minerales	0,015
1711	Hilatura de fibras textiles, tejidos	0,001

CAPITULO III

ANALISIS Y PROCESAMIENTO DE LA DATA MEDIANTE EL SOFTWARE DE NEURAL SOLUTION

En la construcción del modelo de red neuronal se utilizó como herramienta el software *NeuroSolution* versión 3.0, la cual ha permitido realizar el proceso de diseñar y entrenar una red neuronal con el propósito de obtener un modelo neuronal adecuado que se ajusta a la data utilizada en el estudio.

A continuación, se presentan los procesos realizados en la construcción del modelo neuronal [Del Brío y Sanz *et al.*, 2000]:

3.1. PROCESO DE ENTRENAMIENTO DE LA DATA

En primer paso para diseñar la red neuronal se seleccionó la data de entrenamiento, donde se presentan a siete indicadores, seleccionados como variables en estudio y los 73 subsectores o actividades industriales denotado como observaciones. Inicialmente todas las variables se etiquetan como entrada. Asimismo, ya que esta red requiere el entrenamiento dirigido, para el cual se etiquetó una variable designándole como valor deseado o proyectado.

En el proceso de entrenamiento se utilizó 30 subsectores industriales elegidos al azar. En el modo de la predicción, los datos de la columna etiquetado como “Predicción” se usa como entrada y se predecirá las contestaciones para la red, con la entrada tardada por “Delta” muestras.

3.2. VALIDACION CRUZADA Y TEST DE LA DATA

En este proceso se especificó la data para la validación cruzada y para el test. Los datos son extraídos de la data de entrenamiento, de esta forma se empleo solo los ejemplos del conjunto de aprendizaje. La validación cruzada es un método que se utilizó para detener el entrenamiento de la red, ya que este método supervisa o monitorea el error en un grupo independiente de la data y detiene el entrenamiento cuando este error empieza a aumentar. Al punto donde ocurre el desfase se considera como generalización optima. El grupo de prueba es usado para probar el comportamiento de la red. De tal manera que una vez que la red está especializada los pesos quedan estáticos, el grupo de prueba alimenta la red y el rendimiento de la red es comparado con el rendimiento deseado.

3.3. MODELACION DE LA DATA MEDIANTE EL PERCEPTRON MULTICAPA

En esta etapa se seleccionó el modelo de perceptrón multicapa para la clasificación de subsectores industriales, la cuál es entrenado con la red *backpropagation* estático, asimismo aquí se especificó que el modelo a construirse solo era necesario requerir de una capa oculta, en vista que la información no es suficiente. Sus ventajas de este modelo de perceptrón multicapa es, que ellos son fáciles de usar y pueden aproximar cualquier mapa de la data de entrada o salida.

3.4. NUMERO DE CAPAS OCULTAS

En la ventana de capa oculta se especificó los parámetros de la capa oculta y los elementos procesados, estos parámetros son dependientes del modelo neuronal, pero requiere de una función no lineal para especificar el comportamiento de los elementos procesados, de esta manera en el estudio se utilizó una función tangente. Además, cada capa tiene una regla de aprendizaje asociada y parámetros de aprendizaje. El número de elementos procesados y parámetros de aprendizaje están referenciados en correspondencia de los campos. La selección de la regla de aprendizaje y la función de aprendizaje fueron seleccionados de

una lista de opciones que aparecen en el ítem, los cuales fueron seleccionados por defecto por el software para el ratio de aprendizaje, es posible de modificar estos parámetros si se ve que el aprendizaje es inestable o muy lento.

3.5. NIVEL DE SALIDA

En esta etapa se muestra una ventana donde se especifica los parámetros de los elementos procesados. La simulación del software de *Neural Solution* utiliza vectores basados en eficiencia. Esto implica que cada capa contiene un vector de elementos procesados y que los parámetros seleccionados se aplican al vector entero. Los parámetros son dependientes del modelo neuronal, pero requiere de una función no lineal para especificar el comportamiento de los elementos procesados. Además, cada capa tiene una regla de aprendizaje y parámetros de aprendizaje. Es necesario conocer que el número de elementos procesados para la capa de salida es determinado por el número de variables que se seleccionó como predecido.

3.6. APRENDIZAJE SUPERVISADO

Los resultados que se muestran en esta ventana, se especifica el número máximo de épocas, es decir, el número de iteraciones (sobre el grupo de prueba) que deben ser hechos si no hay algún criterio puntual. También hay un campo donde se especifica el error para terminar el entrenamiento, el cual para el presente estudio se aplicó el mínimo margen de error.

Por otra parte, se puede especificar cómo el entrenamiento termina mediante una función de nivel de error deseado. Hay tres funciones para escoger, pero los dos primeros son los más aplicables al cuadrado medio del error del grupo de entrenamiento. La función mínima termina cuando el CME cae por debajo del umbral especificado. La función Incremental termina cuando el cambio en el CME de una iteración a la siguiente está menos del umbral. Es necesario conocer que el umbral predefinido cambia cuando uno selecciona entre las dos funciones. Como es de esperar, el error Incremental predefinido es mucho más pequeño que

el error mínimo. Como se menciono antes, la opción del CME tiende a ser un indicador muy bueno en el nivel de generalización que la red ha logrado.

La otra opción donde se especifica cuando los pesos son actualizados. En línea el aprendizaje actualiza los pesos después de la presentación de cada ejemplar. Sin embargo, en lote el aprendizaje actualiza los pesos después de la presentación del grupo de entrenamiento completo.


3.7. CONFIGURACION DE PRUEBA

En este proceso final de especificación de parámetros para la construcción del modelo neuronal, se especificó el ingreso de la data y la salida de los resultados, así como el almacenamiento de los pesos, errores y valores predecidos por el modelo neuronal. Todo ello fue posible configurar antes de la ejecución del programa, el cuál se mostrará en el modelo neuronal construido a partir de los parámetros asignados en el proceso de construcción.

3.8. MODELO GRAFICO DEL PERCEPTRON MULTICAPA

El modelo de red neuronal construido en el presente estudio es un perceptrón multicapa con una capa oculta, y otras dos una de entrada y salida. Este modelo fue determinado por una serie de iteraciones o épocas, buscando minimizar el error de clasificación mediante el algoritmo *backpropagation*. Por otro lado, los parámetros asignados en el proceso de construcción, son almacenados en una base interna del modelo, así como los pesos y las predicciones. El modelo neuronal obtenido a través de la utilización del software *Neural Solution* versión 3.0 se representa en el siguiente gráfico:

Gráfico N°3: Representación gráfica del modelo de perceptrón multicapa construido mediante el uso del *Software Neural Solution versión 3.0*



A través de las ventanas visuales generadas de la aplicación del sistema mediante el uso del software, nos muestra el procedimiento de forma gráfica realizado en la construcción de la obtención de un modelo adecuado (Ver Anexo N°8). Asimismo, se muestra una ventana de resultado final (valores ingresados, pesos, función de activación gráfica, valores deseados) y el modelo de perceptrón multicapa construido (Ver Anexo N°9).

CAPITULO IV

COMPARACION DE LAS TECNICAS DE REDES NEURONALES Y ESTADISTICAS

4.1. REDES NEURONALES Y ESTADISTICA

La estadística comprende un conjunto de métodos que sirven para recoger, organizar, resumir y analizar datos, así como para extraer conclusiones y tomar decisiones basadas en el análisis. Por su parte, las redes neuronales tienen muchos más aspectos en común con la estadística que con la inteligencia artificial, por lo que han sido descritos como técnicas de ajuste estadístico inspirados en la biología. En ambas disciplinas se han determinados modelos que se emplean en ajuste funcional (Perceptrón y Regresión), en reducción de dimensionalidad (mapas de Kohonen y análisis de componentes principales) y otras tareas [Del Brío y Sanz *et al.*, 2000].

Ambas técnicas tratan de resolver en ocasiones problemas similares, de modo que resulta lógico que lleguen a conclusiones semejantes; de tal manera que parece más adecuada que exista una complementación entre ambas que un enfrentamiento, en tal sentido, las redes neuronales pueden beneficiarse de la estadística en numerosos aspectos, como por ejemplo, el empleo de técnicas estadísticas para el análisis de relevancia de las variables de entrada, su utilización en una inicialización más inteligente que los pesos o en el análisis de la operación de la red.

Ventajas de las Redes Neuronales respecto de las técnicas estadísticas

- Los métodos neuronales, en su forma básica, son relativamente fáciles de emplear y la interpretación de sus resultados resulta comprensible para usuarios no necesariamente expertos en el tema.
- Asimismo, las redes neuronales normalmente no suelen imponer presupuestos de partida, como tipo de dependencia funcional o distribución gaussiana de los datos.
- Otra ventaja es la rápida respuesta de una red neuronal artificial simulado; cuando se requiere una respuesta más rápida aún, la red neuronal puede incluso realizarse electrónicamente en circuitos específicos paralelos.
- Además, debido a la que las redes neuronales tiene la posibilidad de entrenamiento en línea, pueden utilizarse para aplicaciones de control industrial, en las que los patrones van llegando unos tras otros, tarea imposible para una herramienta estadística en la que se requiere la presencia de todos los datos simultáneamente desde el principio.

4.2. RELACIONES ENTRE TECNICAS NEURONALES Y ESTADISTICAS

Las técnicas estadística y las redes neuronales artificiales están muy relacionadas, que ningún campo es a priori mejor que el otro (en algunos casos ambos son indistinguibles incluso), y que lo razonable es aplicar en cada caso la solución más idónea.

Asimismo, se señala el paralelismo entre multitud de modelos estadísticos y neuronales de los cuales se muestran algunos en la siguiente tabla:

Tabla N°8: Algunas relaciones entre técnicas neuronales y estadísticas

Modelo neuronal	Técnica estadística
Perceptrón Simple (nodo tipo umbral)	Análisis discriminante
Perceptrón Simple (nodo tipo sigmoideo)	Regresión logística
Adelina	Regresión lineal
Perceptrón multicapa	Regresión no lineal simple Regresión no lineal multivariada
Aprendizaje hebbiano no supervisado	Análisis de componentes principales
Red simple de Kohonen (competitiva)	Análisis cluster mínimos cuadrados
Cuantificación de vectores LVQ	Análisis discriminante (vecindad)
Funciones de base radial (RBF)	Métodos de <i>kernel regression</i>
Mapas de Kohonen	Escalas multidimensionales

Redes neuronales sin paralelismo claro
Contrapropagación
Redes ART
Modelo de Hopfield

4.3. APLICACION DE LAS TECNICAS ESTADISTICAS

Técnicas estadísticas utilizadas en el análisis de competitividad de las actividades industriales:

a) Análisis de Correlación

Como primer proceso se aplicó el Análisis de Correlación, una de las técnicas estadísticas para analizar el grado de asociación o relación existente entre las variables, en donde cada valor de la relación entre las variables presenta un significado: si el valor es cercano a +1, se dice que la relación existente entre las variables es positiva; si el valor es cercano a -1, se dice que la relación entre ambas variables es inversa [Acuña *et al.*, 1999].

Para el cálculo de cada uno de los coeficientes de la matriz de correlación generada en el Cuadro N°2 se utilizó la expresión matemática mostrado en el Capítulo 2.3. a).

Asimismo, dicho resultado presentado en el Cuadro N°2 indica que las variables de Insumos, Inversión, Exportación, Importación y Stock IED están fuertemente y positivamente relacionadas entre sí, ya que los coeficientes de correlación tienden a +1. Sin embargo, solo la variable TUCI está inversamente relacionada con las Importaciones (-0.132) con bajo el grado de asociación, esto se explica debido a que se está importando mayores productos del exterior dado a una disminución o casi nula en producción, en efecto los establecimientos de producción se encuentran vacíos, existiendo menor tasa de capacidad instalada. Por otro lado, su relación con las demás variables es positiva, lo cual indica que existe una asociación lineal, existiendo una alta relación directa con los indicadores de producción e inversiones debido a que los tienden a +1.

Cuadro N°2:

Correlación (Pearson)

	Producción	Insumos	Inversión	Exportación	Importación	Stock IED	
Insumos	0.982						
Inversión	0.570	0.516					
Exportación	0.590	0.626	0.460				
Importación	0.335	0.407	0.098	0.314			
Stock IED	0.458	0.506	0.178	0.297	0.399		
TUCI	0.408	0.375	0.199	0.209	-0.132	0.228	

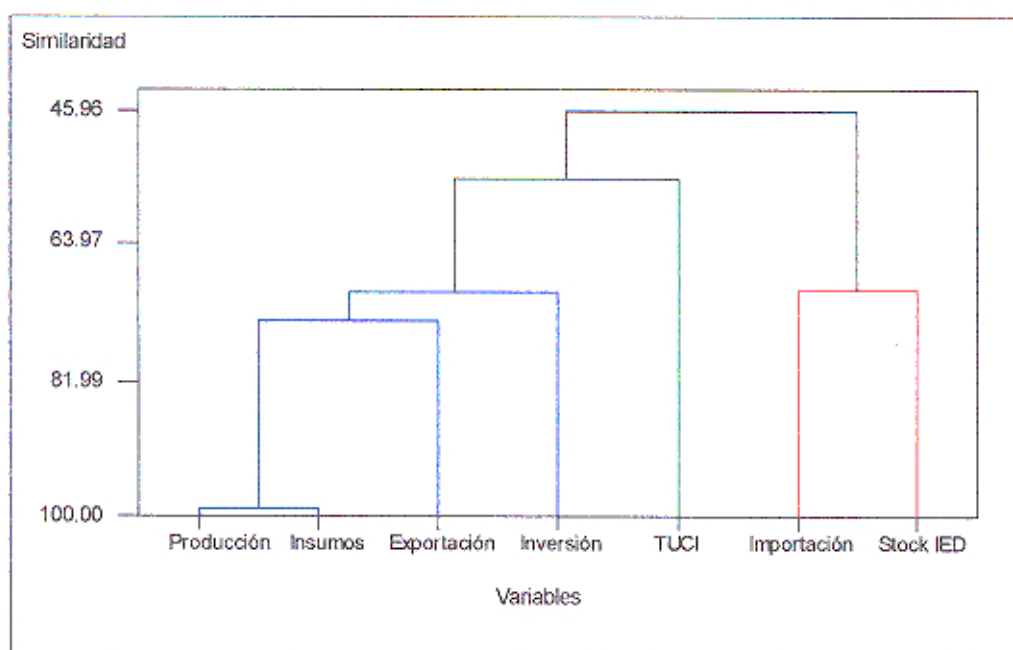
γ

b) Análisis de Cluster

Para la obtención del dendograma de indicadores económicos se aplicó la metodología desarrollada en el Capítulo 2.3.b), donde se tuvo como entrada a siete variables económicas en estudio: Valor Total de la Producción Anual (Producción Industrial), Valor Total de Consumo (Insumo), Valor Total de la Inversión Anual en Activo Fijo (Inversión fija), Exportaciones, Tasa de Utilización de la Capacidad Instalada, Importaciones y Stock de Inversión Extranjera Directa

Con la aplicación de esta técnica de análisis estadístico se tuvo como resultado el dendograma de indicadores económicos representado gráficamente en el Gráfico N°4 donde se observa a tres grupos claramente definidos, las cuales representan las relaciones existentes entre ellas. Esto nos permite identificar a tres nuevas variables o componentes.

Gráfico N°4: Dendograma de Indicadores Económicos



ANÁLISIS DE FACTORES

Una vez determinado el número de componentes a generarse mediante el análisis de cluster, se procedió a aplicar la técnica estadística de Análisis de Factores, con la finalidad de encontrar los factores y sus respectivos coeficientes para la construcción del modelo de competitividad [Acuña *et al.*, 1999].

Cálculo del modelo factorial:

$$X_i = \sum_{j=1}^m \lambda_{ij} f_j + \mu_i + \varepsilon_i, \quad i = 1, 2, 3, \dots, p.$$

Donde:

X_i : representa a la i-ésima variable.

λ_{ij} : es la ponderación de la i-ésima variable con respecto al j-ésimo factor.

f_j : es el j-ésimo factor.

ε_i : es el i-ésimo factor específico asociado sólo con la i-ésima variable X_i .

Cálculo de la matriz de correlación:

$$\text{Corr}(x_i, f_j) = \frac{\lambda_{ij}}{\sigma_i}$$

σ_i es la desviación estándar de la i-ésima variable.

La rotación varimax: Este método de rotación permite obtener algunas ponderaciones de los factores lo más próximos a 1 o -1 y las otras lo más próximas a ceros. Maximizando la variancia de las ponderaciones factoriales al cuadrado correspondiente a un factor.

Según los resultados del Cuadro N°3 con un número de tres factores (nuevas variables), en su conjunto representan el 80% de la variabilidad total, el cual es aceptable contar con dicho número de factores, siendo teóricamente la mínima

50%. Asimismo, los valores de contraste variable / componente representa a la matriz de correlación existente entre ambos.

Siguiendo con el criterio de interpretación de la matriz de correlación cada factor queda comprendido por las variables con mayor grado de asociación (cerca de 1 en valor absoluto). El Factor 1 conformado por: Valor Bruto de la Producción, Valor Total de Consumo, Valor de Inversiones Fijas y Exportaciones en su conjunto se define como Producción y Oferta de mercado. El Factor 2: importaciones e Inversión Extranjera Directa en su conjunto se denominó como Inversiones y el Factor 3: Tasa Utilidad de la Capacidad Instalada representa a Productividad. Por tanto, el

Factor 1, representa un indicador de competitividad para el cual se construye un modelo, a fin de determinar los índices de competitividad y con ello identificar a las actividades industriales que presentan competitividad.

Cuadro N°3:

Análisis de Factor de componentes principales mediante la matriz de correlación

Método: Rotación Varimax

<u>Variable</u>	<u>Factor1</u>	<u>Factor2</u>	<u>Factor3</u>	<u>Comunalidad</u>
Producción	0.774	0.407	0.346	0.885
Insumos	0.747	0.492	0.309	0.896
Inversión	0.857	-0.105	0.048	0.747
Exportación	0.756	0.258	0.019	0.638
Importación	0.202	0.802	-0.357	0.812
Stock IED	0.116	0.795	0.323	0.750
TUCI	0.180	0.019	0.915	0.870
<u>Variancia</u>	2.5	1.8	1.3	5.6
<u>% Var.</u>	36.4	25.2	18.4	80.0

Matriz de Coeficientes: Contribución de las variables con cada factor

<u>Variable</u>	<u>Coef. Factor1</u>	<u>Coef. Factor2</u>	<u>Coef. Factor3</u>
Producción	0.242	0.067	0.126
Insumos	0.210	0.139	0.098
Inversión	0.520	-0.342	-0.164
Exportación	0.357	-0.039	-0.167
Importación	-0.042	0.540	-0.372
Stock IED	-0.255	0.561	0.264
TUCI	-0.123	-0.041	0.785

t

Es a partir de los coeficientes de factores calculados que permitieron la representación de un modelo estadístico generado por las tres nuevas variables. Es a partir del modelo generado que se obtiene los *scores* para cada actividad económica industrial, el cual se interpreta de la siguiente manera: el valor positivo significa que la actividad industrial es competitiva, mientras que un valor negativo significa que el sector es no competitivo.

CONSTRUCCION DEL MODELO ESTADISTICO PARA EL INDICADOR DE COMPETITIVIDAD

$$\text{IND - COMP}_j = \sum_{i=1}^7 (B_i) \left[\frac{V_{ij} - \mu_i}{S_i} \right]$$

Para $i =$ Variables, $j =$ CIUs (1511,1513,...,3699)

Donde:

IND - COMP: Es el Indicador de Competitividad

B_i : Representa la contribución de la variable i .

V_{ij} : Representa el valor de la variable i , para el CIU j .

μ_i : Representa el promedio de las observaciones en la variable i .

S_i : Representa la desviación estándar de las observaciones en la variable i .

Resultados obtenidos con el cálculo de los índices de competitividad

- Mediante la aplicación de las técnicas estadísticas, en particular, el análisis de factores permitió determinar el nivel de competitividad de los subsectores industriales utilizando para ello un modelo construido a partir de los factores generados (tres indicadores económicos). en base a este modelo hallado se calculó los *scores* o puntajes para cada subsector, como se muestra en la Tabla N°9. Donde se destaca entre los subsectores con mayor puntaje o competitividad

a la industria de Hilatura de fibras textiles y en segundo lugar a la industria de refinación de petróleo. Por el lado de los subsectores no competitivos se destaca a la industria de actividades de impresión, seguido de ello, Otras industrias manufactureras.

- En resumen, de los 73 Subsectores Industriales evaluados, 56 subsectores no son competitivos pero se conoce que la mayoría de ellos orientan su producción al mercado interno. Mientras que solo 17 subsectores industriales son competitivos, es decir, estos subsectores orientan su producción en un mayor volumen al mercado externo y local
- El porcentaje de clasificación correcta mediante la técnica de análisis discriminante (Ver Anexo N°3), se obtuvo el 91,8% de los subsectores, con un cuadrado medio de error de 2.5, el cual representa una baja variabilidad del modelo, significando ello que los datos se ajustan al modelo.

Tabla N°9:

Índice de Competitividad por Actividad Económica (CIUs)

SUBSECTORES INDUSTRIALES COMPETITIVOS

CIU	DESCRIPCION	IND-COMP
1711	Hilatura de fibras textiles, tejidos	5.16
2320	Producción de refinación del petróleo	3.39
1730	Tejidos y artículos de punto y ganchillo	2.78
2720	Metales preciosos y no ferrosos, primarios	2.45
1810	Prendas de vestir, excluye prendas de piel	2.24
2520	Productos de plástico	1.60
1513	Elaborados de frutas, legumbres y hortalizas	0.84
2010	Aserrado, acepilladura madera	0.69
2694	Cemento, cal y yeso	0.59
2710	Industrias básicas de hierro y acero	0.57
1531	Productos de molinería	0.42
1520	Productos lácteos	0.23
2693	Productos de arcilla y cerámica no refractaria para uso estructural	0.14
1549	Otros productos alimenticios n.e.p.	0.09
1542	Refinerías de azúcar	0.07
2411	Sustancias químicas básicas	0.05
2899	Otros productos de metal n.c.p.	0.02

SUBSECTORES INDUSTRIALES NO COMPETITIVOS

CIU	DESCRIPCION	IND-COMP
2221	Actividades de impresión	-0.01
3699	Otras industrias manufactureras n.c.p.	-0.02
1533	Alimentos preparados para animales	-0.05
2109	Articulos de papel y cartón	-0.06
1554	Bebidas no alcohólicas, aguas minerales	-0.06
2924	Maquinaria para minas, canteras y construcción	-0.08
3691	Joyas y articulos conexos	-0.13
2102	Papel, cartón ondulado y de envases de papel y cartón	-0.16
3610	Muebles	-0.16
2811	Producción metálicos uso estructural	-0.18
3420	Carrocerías para vehículos automotores, remolques y semiremolques	-0.18
2695	Articulos hormigón, cemento y yeso	-0.19
2423	Productos farmacéuticos, botánicos	-0.22
2732	Fundición de metales no ferrosos	-0.24
1541	Productos de panadería	-0.25
1920	Calzado	-0.26
2429	Productos químicos n.e.p.	-0.28
1553	Bebidas malteadas y de malta	-0.30
3592	Bicicletas y sillones de ruedas	-0.31
1911	Curtido y adobo de cueros	-0.32
3120	Aparatos de distribución y control de la energía eléctrica	-0.32
3110	Motores, generadores y transformadores eléctricos	-0.33
2424	Jabones, detergentes, productos de limpieza y tocador	-0.33
3312	Instrumentos y aparatos para medir y otros afines, excepto de control de procesos industriales	-0.34
2610	Vidrio y productos de vidrio	-0.34
2919	Otros tipos maquinas uso general	-0.35
2930	Aparatos de uso doméstico n.c.p.	-0.35
2412	Abono y compuestos de nitrógeno	-0.37
2421	Plaguicidas y otros químicos de uso agropecuario	-0.37
1511	Carne y productos cárnicos	-0.38
2911	Motores y turbinas, excepto motores para aeronaves, vehículos automotores y motocicletas	-0.40
3591	Motocicletas	-0.40
2021	Hojas de madera para enchapado, tableros contrachapados, laminados, de partículas	-0.40
2212	Periódicos, revistas y publicaciones periódicas	-0.41
1552	Elaboración de vinos	-0.43
2422	Pinturas, barnices y productos similares	-0.44
3430	Partes, piezas y accesorios para vehículos automotores y sus motores	-0.45
1551	Destilación, rectificación mezcla bebidas alcohólicas	-0.45
2699	Otros productos minerales no metálicos n.c.p.	-0.46
2912	Bombas, compres, grifos, válvulas	-0.46
2101	Pasta de madera, papel y cartón	-0.48

2430	Fibras manufacturadas	-0.48
2731	Fundición de hierro y acero	-0.50
1532	Almidones y derivados del almidón	-0.55
1723	Cuerdas, cordeles, bramantes y redes	-0.56
3410	Vehículos automotores	-0.56
2893	Artículos de cuchillería y ferretería	-0.56
3140	Acumuladores, pilas y baterías primarias	-0.57
2511	Cubiertas y cámaras de caucho	-0.62
2413	Plásticos en formas primarias y de caucho sintético	-0.63
2691	Productos de cerámica no refractaria para uso no estructural	-0.66
1543	Elaboración de cacao, chocolate y confitería	-0.67
1600	Productos de tabaco	-0.72
1514	Accites y grasas, vegetal y animal	-0.75
3130	Hilos y cables aislados	-0.83
1544	Macarrones, fideos y farináceos	-0.93

4.4. ANALISIS COMPARATIVO DE RESULTADOS: TECNICAS DE REDES NEURONALES Y ESTADISTICAS MULTIVARIADAS

Para evaluar la eficiencia del modelo de redes neuronales (perceptrón multicapa) en contraste con las técnicas estadísticas multivariadas se realizó el modelamiento de los datos y las pruebas respectivas obteniendo la clasificación de las actividades industriales según el nivel de competitividad, en el caso de la aplicación mediante redes neuronales se determinó cuatro grupos de acuerdo al grado de competitividad, dos de ellos determinan a los subsectores competitivos “Altamente competitivos y Competitivos” y los dos restantes a los no competitivos “Oportunidades pérdidas y Retroceso”. Mientras que con la aplicación de técnicas estadísticas se determinó a dos grupos subsectores industriales “Competitivos y No competitivos”. En cada una de las técnicas aplicadas se ha determinado el porcentaje de clasificación correcto y el grado de error.

Como resultado de aplicar la metodología de las RNAs en el proceso de clasificación sobre los 73 Subsectores Industriales; 35 subsectores industriales resultaron ser competitivos, el cual se explica porque estos orientan su producción en un mayor volumen al mercado externo y local. Mientras que los 38 subsectores restantes se clasificaron como no competitivos, notándose que un

grupo de estos abastecen todo o lo poco que producen al mercado interno y otros permanecen estancados. En el caso, de los resultados obtenidos con la aplicación de las técnicas estadísticas, de los 73 Subsectores Industriales evaluados, sólo 17 subsectores industriales son competitivos, es decir, estos subsectores orientan su producción en un mayor volumen al mercado externo y local, mientras que 56 Subsectores no son competitivos pero se debería a que la mayoría de estos orientan su producción al mercado interno.

En la clasificación de las actividades industriales existen diferencias en cuanto a los resultados obtenidos por una u otra técnica, sin embargo, se destaca la eficiencia de las técnicas de redes neuronales debido a que para la predicción de la clasificación de los subsectores se basa de un modelo supervisado que utiliza una variable control; que muestra el desempeño externo de las actividades industriales - CIUs en materia comercial, y se construye en base a las exportaciones y/o importaciones de las actividades desagregadas a cuatro dígitos del CIU bajo la restricción de obtener un indicador con enfoque interno, el cual se denomina “Indicador de competitividad relativa” utilizado por la ONUDI (1985), [Comisión económica para América latina, 2000]. Mientras que las técnicas estadísticas no considera esta información que es relevante y donde radicaría la diferencia.

Como consecuencia de esto, 27 subsectores industriales fueron clasificados como no competitivos mediante ésta técnica cuando deberían ser competitivos (Ver Tabla N°10). Al analizar la competitividad de estos subsectores con una mayor detalle sobre las variables económicas que explican la competitividad y los pesos determinados para cada una de éstas, se encuentra el sustento del porqué de estas diferencias, el modelo generado por las redes neuronales priorizan su peso o contribución al indicador de competitividad en las exportaciones, el stock de inversión extranjera directa y los insumos utilizados en la producción, los cuales son variables determinantes para la oferta exportable y por ende de competitividad. Sin embargo, mediante el modelo estadístico se ha generado un mayor peso a la inversión fija, seguido las exportaciones y producción, el cual se estaría incurriendo en una mala clasificación de

competitividad al suponer que los subsectores que no han realizado inversión en el año 2000 no sean competitivos, ya que la inversión en maquinarias u otros bienes de activos fijos utilizados en la producción pudieron haberse efectuado el año anterior, esto se presenta frecuentemente en los bienes de consumo e intermedio.

Tabla N°10:

CIU	DESCRIPCION	CLASIFICACION	
		MODELO RNA	MODELO ESTADISTICO
1531	Productos de molinería	Competitivo	No competitivo
1543	Elaboración de cacao, chocolate y confitería	Competitivo	No competitivo
1549	Otros productos alimenticios n.e.p.	Competitivo	No competitivo
1552	Elaboración de vinos	Competitivo	No competitivo
1920	Calzado	Competitivo	No competitivo
2021	Hojas de madera para enchapado, tableros contrachapados, laminados, de partículas	Competitivo	No competitivo
2101	Pasta de madera, papel y cartón	Competitivo	No competitivo
2102	Papel, cartón ondulado y de envases de papel y cartón	Competitivo	No competitivo
2413	Plásticos en formas primarias y de caucho sintético	Competitivo	No competitivo
2421	Plaguicidas y otros químicos de uso agropecuario	Competitivo	No competitivo
2422	Pinturas, barnices y productos similares	Competitivo	No competitivo
2423	Productos farmacéuticos, botánicos	Competitivo	No competitivo
2429	Productos químicos n.e.p.	Competitivo	No competitivo
2610	Vidrio y productos de vidrio	Competitivo	No competitivo
2695	Artículos de hormigón, cemento y yeso	Competitivo	No competitivo
2732	Fundición de metales no ferrosos	Competitivo	No competitivo
2811	Productos metálicos uso estructural	Competitivo	No competitivo
2893	Artículos de cuchillería y ferretería	Competitivo	No competitivo
2899	Otros productos de metal n.e.p.	Competitivo	No competitivo
2912	Bombas, compres, grifos, válvulas	Competitivo	No competitivo
2924	Maquinaria para minas, canteras y construcción	Competitivo	No competitivo
3110	Motores, generadores y transformadores eléctricos	Competitivo	No competitivo
3410	Vehículos automotores	Competitivo	No competitivo
3430	Partes, piezas y accesorios para vehículos automotores y sus motores	Competitivo	No competitivo
3610	Muebles	Competitivo	No competitivo
3691	Joyas y artículos conexos	Competitivo	No competitivo
3699	Otras industrias manufactureras n.e.p.	Competitivo	No competitivo

Asimismo, también hubo diferencia en la clasificación de 3 subsectores industriales al clasificarse como competitivos mediante la técnica estadística cuando no lo serían, según los resultados obtenidos por el modelo de redes neuronales, estos subsectores industriales son los siguientes: Productos lácteos (CIU 1520), Hilatura de fibras textiles, tejidos (CIU 1711) y la Industria de cemento, cal y yeso (CIU 2694), el cual se estaría realizando una clasificación incorrecta de estos subsectores, al suponer de que estos a pesar de presentar un mayor nivel de producción e inversión son competitivos, no considerando que la mayor parte de su producción es destinada únicamente para satisfacer la demanda local. De acuerdo al mayor peso o contribución determinado por el modelo de redes neuronales a la variable de exportaciones, estos subsectores no serían competitivos. Esto también se ve reflejado en la mayor importación de estos bienes para satisfacer la demanda interna.

Al respecto, como etapa final se realizó una comparación sobre los estimadores de eficiencia en los modelos generados mediante la aplicación de redes neuronales y las técnicas estadísticas, donde se encontró que el modelo de redes neuronales supervisado que se construyó, ha realizado una mejor clasificación frente al modelo estadístico generado. Tal es así, que en la clasificación de los 73 Subsectores Industriales mediante la técnica estadística se obtuvo el 91,8% de clasificación correcta con un cuadrado medio de error 2.5, mientras que, con el modelo neuronal se obtuvo el 100% de clasificación correcta con un error mínimo de 0.2, el cual significa que los datos se ajustan mucho mejor al modelo de redes neuronales presentando una variabilidad muy baja.

CONCLUSIONES Y RECOMENDACIONES

CONCLUSIONES

- En el presente trabajo de investigación se exponen ampliamente las bases de una disciplina que ha sufrido una producción científica en los últimos años. De manera sorprendente, estos métodos han sido extensamente utilizados en otros campos del conocimiento, entre ellos en el campo industrial como elementos de ayuda. No obstante, la metodología que se aplicó es el modelo de perceptrón multicapa, con una capa oculta, junto con el algoritmo de aprendizaje *backpropagation*, el cual ha proporcionado resultados altamente satisfactorios con un menor porcentaje de error en la clasificación de subsectores industriales competitivos.
- De los resultados obtenidos se concluye y a su vez se reafirma como una herramienta potencial en la clasificación de datos, el uso de la técnica de redes neuronales siendo más eficiente que las técnicas estadísticas.
- Se ha propuesto un sistema de aplicación de una red neuronal artificial, que ha demostrado ser de gran utilidad en la clasificación de patrones para determinar el nivel de competitividad de los subsectores industriales, teniendo como condición mínima necesaria la utilización de una base de datos a 73 actividades industriales (CIUs) y siete variables económicas como: producción industrial, insumos, inversión fija, exportaciones, importaciones, stock de inversión extranjera directa y tasa de utilización de capacidad instalada, siendo estas variables relevantes en la generación del indicador de competitividad.

- La ventaja de aplicar la técnica de las redes neuronales artificiales constituye un útil y potente conjunto de herramientas a diferencia de modelos matemáticos y estadísticos los cuales intentan “ajustar los datos a un modelo”; las redes neuronales artificiales “fabrican un modelo que se ajusta a los datos”, debido a las características de flexibilidad y adaptabilidad, ya que se puede añadir un gran número de métodos de procesamiento y control disponible, y que deberán ser utilizado donde sea apropiado.
- En comparación con las técnicas estadísticas, las redes neuronales son herramientas útiles como un nuevo camino para el análisis de datos que complementan los análisis estadísticos tradicionales. A diferencia de estos, las redes neuronales no requieren de suposiciones sobre la forma de distribución de los datos para poder ser analizados (linealidad, normalidad, etc.) supuestos que muy pocas veces se cumplen.
- Los resultados obtenidos mediante la aplicación de las redes neuronales artificiales en la clasificación de los 73 Subsectores Industriales se obtuvo el 100% de clasificación correcta con una variabilidad de los datos en 0.2. Mientras con la aplicación de técnicas estadísticas se obtuvo el 91,8% de clasificación correcta de los subsectores con una variabilidad de 2.5. Frente a ello, se demuestra que la técnica de redes neuronales es eficiente en comparación a la técnica estadística.
- El análisis de competitividad del Sector Industrial Manufacturero, donde se aplicó 73 subsectores industriales mediante la técnica de redes neuronales, concluye que 35 subsectores industriales son competitivos, es decir, su producción está orientada en un mayor volumen al mercado externo y local. Mientras que 38 subsectores no presentan competitividad, sin embargo un grupo de ellos (13 subsectores industriales) estarían incrementando su nivel de producción y oferta exportable, por lo que sería necesario aplicar normas, convenios, políticas de apertura y reactivación de estos subsectores, a fin de que le permita ganar competitividad en el mercado local y externo.

- Por otro lado, se concluye que la Industria Manufacturera en el Perú en estos últimos años ha incrementado su nivel competitividad, en relación a años anteriores, debido a que de los 73 subsectores industriales que comprende el sector, en el periodo 1995-1999, en promedio 30 subsectores eran competitivos, el resto pertenecían al grupo de actividades industriales con oportunidades perdidas o en retroceso. Como consecuencia de que la mayoría de estas actividades industriales aumentaban la productividad de sus insumos al mismo tiempo que sustituyen insumos nacionales por importados, ello se puede observar en sus altos niveles de importación.
- La industria Manufacturera, y por tanto la economía durante la década de los 90s se había hecho más dependientes de las importaciones. Significando así la reducción del mercado interno para la industria manufacturera tras ocasionar la sustitución de la industria nacional por la producción importada. Este efecto sustitución en el periodo 2000 ha reducido por el incremento de las exportaciones manufactureras, lo que se vería reflejado en el incremento de actividades industriales competitivas y un mayor grupo no competitivo con esperanza de ganar competitividad.

RECOMENDACIONES

- A pesar que las redes neuronales artificiales no se constituyen como una herramienta nueva de conocimiento, considero que aún en el país no se le está brindando la debida importancia, teniendo en cuenta las ventajas que presenta sobre otras técnicas para la solución de cierto tipos de problemas complejos en los diversos campos de aplicación: investigación de mercados, análisis financieros, farmacéutica, y otros.
- En cuanto al conocimiento necesario para realizar la clasificación de patrones estadísticamente o mediante la utilización de la técnica de redes neuronales podemos decir que es menor en el caso de las redes neuronales. Sin embargo, el usuario necesita saber e identificar qué topología y método de entrenamiento debe aplicar para cada caso en particular.
- En el enfoque de las redes neuronales artificiales es necesario analizar cómo afecta la cantidad de datos que se utilicen como entrada sobre el rendimiento de los métodos analizados, ya que de ello dependerá la elección adecuada del modelo y por ende los resultados coherentes ha obtenerse.
- Se recomienda tener cuidado en el criterio de selección de variables para el desarrollo de una aplicación mediante la técnica de redes neuronales, ya que sería conveniente apoyarse de una técnica distinta de solución, empleando así herramientas estadísticas como: análisis de correlación o modelos de regresión, para identificar el grupo de variables significativas ha emplearse. De lo contrario podría obtenerse un modelo que conlleve ha resultados no coherentes o aceptable.

- Diseñar una herramienta que desarrolle aplicaciones de redes neuronales y trabaje en conjunto con los métodos estadísticos conduciría a la integración del sistema de competitividad. Implementándose en su desarrollo el aprendizaje sin supervisión, aplicación que prescindiría del supervisor para elegir la arquitectura adecuada, realizar el entrenamiento y finalmente, clasificar e identificar los subsectores industriales competitivos.
- Implementarse las proyecciones en el desarrollo del sistema de competitividad le daría mayor valor agregado, utilizándose informaciones de años pasados, ya que no es factible contar con información actualizada. De esta manera sería posible analizar y conocer la perspectiva de cada subsector industrial y tomar decisiones hacia futuro con respecto a las actividades industriales que no presenten un nivel de competitividad favorable o se encuentren en retroceso.
- La aplicación de la técnica de redes neuronales en el análisis de competitividad del Sector Industrial Manufacturero es base para la realización de estudios en otros sectores económicos del Perú entre ellos: minería, comercio, turismo, pesca y otros, ya que se cuenta con una amplia base de información actualizada en dichos sectores.

BIBLIOGRAFIA

1. Acuña Fernández, Edgar: "Análisis de Datos Estadísticos usando Minitab para Windows", Lima. 1999.
2. Centro de Investigación en Finanzas y Mercado de Capitales: "Indicador Líder del nivel de actividad de la Economía Argentina: Descripción de la metodología", Argentina.2002.
3. Checkland Peter: "Metodología de Sistemas Suaves en Acción", Editorial Wiley. México. 1994.
4. Comisión Económica para América Latina: "Análisis de la Competitividad del Sector Industrial Peruano - Metodología CAN PLUS", Perspectiva Industrial N°4. Lima.2000
5. Del Brío Bonifacio Martín y Sanz Molina Alfredo: "Redes Neuronales y Sistemas Difusos; 2da. Edición ampliada y actualizada", RA-MA Editorial. España. 2002.
6. García Estévez Pablo: "Las aplicaciones de las redes neuronales en finanzas" Documento de trabajo, Facultad de Ciencias Económicas y Empresariales, Madrid.2002
7. Hilerá José R. y Martínez Víctor J.: "Redes Neuronales Artificiales: Fundamentos, modelos y aplicaciones", RA-MA Editorial. España. 2000.
8. Horta Roberto y Jung Andrés: "Análisis de la Competitividad e Industria Manufacturera", Revista FCE N°1. Uruguay.2003.

9. Investigación del Centro de Estudios Latinoamericano: “Los impactos de las políticas de ajuste estructural sobre el empleo y las condiciones de vida de los ecuatorianos mediante las técnicas de redes neuronales”, Ecuador.2001.
10. Jiménez Félix, Aguilar Giovanna y Kapsoli Javier: “Competitividad en la Industria Manufacturera Peruana”, Documento de Trabajo N° 148, 1998.
11. Jiménez Félix, Aguilar Giovanna y Kapsoli Javier: “Competitividad, rendimientos crecientes y comercio intra-industrial en la Manufactura peruana”, Documento de Trabajo N° 153, 1998.
12. Kapsoli Salinas Javier; Bencich Aguilar Brigitt: “Indicadores Líderes, Redes Neuronales y Predicción de corto plazo”, Lima. 2002.
13. Koskivaara Eija: “Artificial Neural Networks in Auditing: State of the Art”, TUCS Technical Report No 509. Finlandia.2003
14. Limsombunchai Visit, Gan Christopher y Lee Minsoo: “Predicción del precio de una casa: Modelo de precio Hedonic versus Red Neuronal Artificial”, American Journal of Applied Sciences N°1, Nueva Zelanda.2004.
15. Mallo González, Carlos: “Un modelo de Red Neuronal Artificial aplicado en la predicción de la demanda horaria de energía eléctrica”, España.2003.
16. Mat Junoh, Mohd: “Predicting GDP growth in Malaysia using knowledge-based economy indicators: a comparison between neural network and econometric approaches”, Sunway College Journal, Vol.1. pp 39-50. Malaysia.2004.
17. Montaña Moreno, Juan: “Redes Neuronales Artificiales aplicados al análisis de datos”, Tesis Doctoral, Universidad de las Islas Baleares, Palma de Mallorca.2002.
18. Noket, S., Britos, P. y García Martínez, R.: “Pronóstico de ventas basada en la comparación de la técnicas de redes neuronales y método estadístico”, Departamento de Ingeniería Industrial, Argentina.2003.

19. Olson, D., Mossman, Ch.: "Neural network forecasting of Canadian stock returns using accounting ratios", *International Journal of Forecasting*, Vol. 19. Canada. 2003.
20. Palmer, A., Montaña, J.J. y Jiménez, R.: "Tutorial sobre redes neuronales Artificiales - el perceptrón multicapa", *Revista electrónica N°5*, España.2001.
21. Philip Hans, Franses y Dick van, Dijk: "Non-linear time series models in empirical finance", Cambridge University Press, Londres. 2000.
22. Pitarque Alfonso, Roy Juan Francisco y Ruiz Juan Carlos: "Redes Neurales versus Modelos estadísticos: Simulaciones sobre tareas de predicción y clasificación", Valencia. España. 1998.
23. Romani G., Aroca P., Aguirre N., Leiton P. y Muñoz J.: "Modelos de clasificación y predicción de quiebra de empresas: una aplicación a empresas chilenas", *Forum Empresarial*, Universidad Católica del Norte, Chile.2000.
24. Saavedra, Jaime: "La liberalización comercial de la industria manufacturera en el Perú", *Consortio de Investigación Económica*. 1996.
25. Shachmurove Yochanan y Witkowska Dorota: "Dynamic interrelations among major world stock markets: a neural network analysis", *International Journal of Business*, Vol.6. Issue N°1. New York.2001.
26. Stéphane Garelli: "The World Competitiveness Landscape in 2005: A higher degree of risk", *IMD World Competitiveness Yearbook 2005*.
27. Timotej Jagric: "A nonlinear approach to forecasting with leading economic indicators", *Studies in Nonlinear Dynamics & Econometrics*, Vol.7. Issue N°2, República Eslovenia.2003.
28. Torrente, Daniela y Gusinsky de Gelman, Susana: "Competitividad de la Industria Argentina y Chaqueña", *Revista de la FCE*, N°1. Argentina.2001.

29. Torres, Zorrilla Jorge: "Cluster de la Industria en el Perú", Documento de Trabajo N° 228, Lima.2003.
30. Von Bertalanffy: "Teoría General de los Sistemas: Fundamentos, desarrollo, aplicaciones", Fondo de Cultura Económica. Edición N°16.México 2004.
31. Zhang Guoqiang, B. Eddy Patuwo y Michael y Hu: "Forecasting with artificial neural networks: The state of the art", International Journal of Forecasting, Vol.14. pp 35-51.1998.

DIRECCIONES EN INTERNET:

32. Introducción a las Redes Neuronales Artificiales, Catalina Gallego Alfredo (<http://www.gui.uva.es>.)
33. Tutorial de Redes Neuronales. Universidad Politécnica de Madrid, España (<http://www.gc.ssr.upm.es/inves/neuronal/ann2/anntuto.htm>.)
34. Tutorial: "What is an Artificial Neural Networks by NeuroSolution", Gainesville, Florida, USA. (<http://www.nd.com/welcome/whatisnn.htm>.)