



UNIVERSIDAD AUSTRAL DE CHILE
Facultad de Ciencias Veterinarias

Facultad de Ciencias Agrarias
Instituto de Ciencia y Tecnología de
los Alimentos

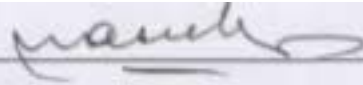
Exploración del uso potencial de las redes neuronales para la
clasificación de la leche según rango celular

Tesis de grado presentada como parte de
los requisitos para optar al Grado de
LICENCIADO EN MEDICINA VETERINARIA

Claudio Nicolás García Salazar
Valdivia Chile 1999

PROFESOR PATROCINANTE

Dr. Bernardo Fraser L.

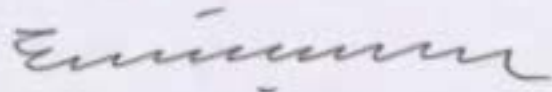


PROFESOR COPATROCINANTE

COLABORADOR

PROFESORES CALIFICADORES

Prof. Erwin Carrasco R.



Prof. Martín Solar M.



FECHA DE APROBACION

CON TODO MI AMOR

A MIS PADRES

A MI ESPOSA

A MI HIJA

INDICE

1.- RESUMEN.....	1
2.- SUMMARY.....	2
3.- INTRODUCCION.....	3
3.1 Redes Neuronales Artificiales	3
3.2 Células somáticas	15
3.3 Propiedades físico - químicas y de composición de la leche	16
3.4 Objetivo.....	18
4.- MATERIAL Y METODOS	19
4.1 Origen y pretratamiento de los datos	19
4.2 Análisis de los datos	20
5.- RESULTADOS.....	22
6.- DISCUSION.....	26
6.1 Conclusiones	26
7.- BIBLIOGRAFIA.....	28
8.- ANEXOS.....	32
AGRADECIMIENTOS.....	44

1. RESUMEN

El principal objetivo de la presente investigación fue aplicar la metodología de las Redes Neuronales Artificiales (RNA), para la clasificación de la leche cruda, según su contenido celular.

Los resultados del análisis de 192 muestras de leche cruda a granel se utilizaron en este estudio, de los cuales 170 se emplearon en la fase de entrenamiento de la red neuronal y 22 muestras en la fase experimental, destinada a probar el poder predictivo de aquella.

La red neuronal consistió de 11 entradas correspondientes a las propiedades seleccionadas. En cuanto a las salidas dos fueron consideradas, una para el caso de un contenido de células somáticas mayor o igual a 300.000 cél/ml y otra en caso de un conteo celular inferior a 300.000 cél/ml.

La selección de las propiedades se realizó determinando el coeficiente de variación, ya que para un mejor aprendizaje de la red, se descartan aquellas propiedades que presentan un rango de variación menor a 5 %.

Todos los datos disponibles fueron normalizados para que sus valores queden comprendidos entre 0 y 1.

El poder de predicción de la red neuronal artificial de las 22 muestras experimentales, alcanzó a 18 aciertos, lo que representa un nivel de confiabilidad de un 81,8 %, para predecir el contenido de células somáticas en leche cruda a partir de sus propiedades físico-químicas y de composición.

Palabras claves: Redes Neuronales Artificiales, Células Somáticas, Propiedades Físico-Químicas y de Composición.

2. SUMMARY

The main purpose of the present research was the application of the so called Artificial Neural Networks (ANN) for the classification of raw milk, according to its somatic cell count.

192 samples of raw milk in bulk were included in this research. 170 samples participated in the training step of network and additional 22 samples were considered in the experimental phase, in order to evaluate the predictive power of the ANN.

The structure of the network consisted of 11 inputs, representing each of them the various physico-chemical and composition properties. As far as the outputs, only 2 were taken into account: the first one in case of a somatic cell count equal or higher than 300.000 cell/ml and the other in case of cellular counting lower than 300.000 cell/ml.

For selecting the different properties variation coefficients were calculated, since for a better learning of the network, all of the properties showing a range of variation lower than 5 % were rejected.

Data were normalized in order the values could remain between 0 and 1.

The Artificial Neural Network was able to correctly predict 18 out of 22 samples, wich is equivalent to a 81,8 % success.

Key words: Artificial Neural Networks, Somatic Cell Count, Physical, Chemical and Compositional Properties.

3. INTRODUCCION

3.1 REDES NEURONALES ARTIFICIALES.

La teoría y el modelado de las redes neuronales artificiales (RNA) está inspirado en los estudios de la estructura y funcionamiento del cerebro y sistema nervioso (tal estudio es denominado neurociencia), en donde la neurona es el elemento fundamental (Aleksander y Morton, 1991, citado por Zhou, 1994; Hilera y Martínez, 1995).

El cerebro es una estructura compleja de células interconectadas, estas células se llaman neuronas. Toda actividad humana es dependiente de las interconexiones de las neuronas, tales conexiones son llamadas redes neuronales (Zhou, 1994).




Figura 1. Esquema de una neurona típica

La característica de la neurona que la diferencia de otras células vivas, es su capacidad de comunicarse, por medio de las conexiones existentes entre ellas. Se calcula que en el cerebro humano existen alrededor de 10^{11} neuronas y 10^{14} o más de 10^{15} sinapsis o conexiones (Andina, 1996; Hilera y Martínez, 1995). Las dendritas (aférentes) reciben señales desde los axones de otras neuronas y las conducen hacia el cuerpo celular o soma. El espacio existente entre el axón de una neurona y la dendrita de otra se denomina sinapsis, es decir, es el punto de conexión. El axón eférente conduce los impulsos desde el soma hacia el exterior de la neurona (Ganong, 1992).

La función de la neurona es integrar las entradas recibidas por las dendritas a través de la sinapsis, y generar o no un potencial de acción, ya sea excitatorio o inhibitorio (Ganong, 1992).

Los investigadores están retornando a los sistemas neuronales biológicos como un modelo para un nuevo paradigma computacional. Los neurocientíficos han aprendido bastante acerca de los sistemas neuronales biológicos en las décadas recientes y los ingenieros están usando esta información, para crear sistemas neuronales artificiales en el laboratorio, y producto de esto, es que se expandió enormemente nuestro poder para procesar y manejar la información (Nelson e Illingworth, 1991; Aleksander y Morton, 1991, citado por Zhou, 1994).

Las RNA no son una herramienta nueva, sino que su historia es tan larga como cualquiera de los métodos convencionales en el área de la computación. Sus inicios se remontan hacia la década de los '40s, específicamente en 1943, donde los primeros fundamentos teóricos para el desarrollo de la computación neuronal fueron propuestos por Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, los que formularon una teoría sobre la forma de trabajar de la neurona, al modelar una red neuronal simple mediante circuitos eléctricos (Andina, 1996; Hilera y Martínez, 1995).

Las redes neuronales artificiales son programas computacionales que simulan el comportamiento básico de un número limitado de neuronas biológicas, usando abstracciones matemáticas y algoritmos computacionales que mantengan las características y relaciones entre ellas conocidas por la biología (Clark, 1997; Urrutia, 1997).

Las RNA al igual que el cerebro, está compuesto por elementos básicos (neuronas), altamente interconectados entre ellos y con modelos de respuestas para cada elemento en función de su entorno, muy parecido al comportamiento de las neuronas biológicas. El cerebro tiene receptores sensoriales para las entradas y neuronas motoras para las salidas. En forma similar, las unidades artificiales que forman la capa de entrada actúan como "sensores", recibiendo sus entradas desde el exterior de la red. Las unidades que no están en la capa de entrada reciben sus entradas desde otras unidades. Estas entradas colectivas son procesadas. Si la fuerza total de la entrada excede un cierto umbral, la unidad envía una señal a otras unidades. Las unidades de la capa externa producen la "actividad" de la salida externa del sistema. Los modelos de respuesta que presentan las neuronas, son simulados en ordenadores convencionales y es el comportamiento colectivo de todos los elementos de procesamiento, lo que le confiere las características especiales para la resolución de problemas complejos. Las RNA como las personas, aprenden a partir de ejemplos (Andina, 1996; Nelson e Illingworth, 1991).

La representación de una típica red neuronal artificial es la que muestra la figura 2, en este caso se trata de una red "feedforward" (con todas las conexiones hacia adelante) multinivel. Cada neurona o nodo únicamente está conectada con neuronas de un nivel superior. Se aprecia que hay muchas más conexiones que nodos. En este sentido, se dice que una red está totalmente conectada si todas las salidas desde un nivel llegan a todos y cada uno de los nodos del nivel siguiente (Hilera y Martínez, 1995).

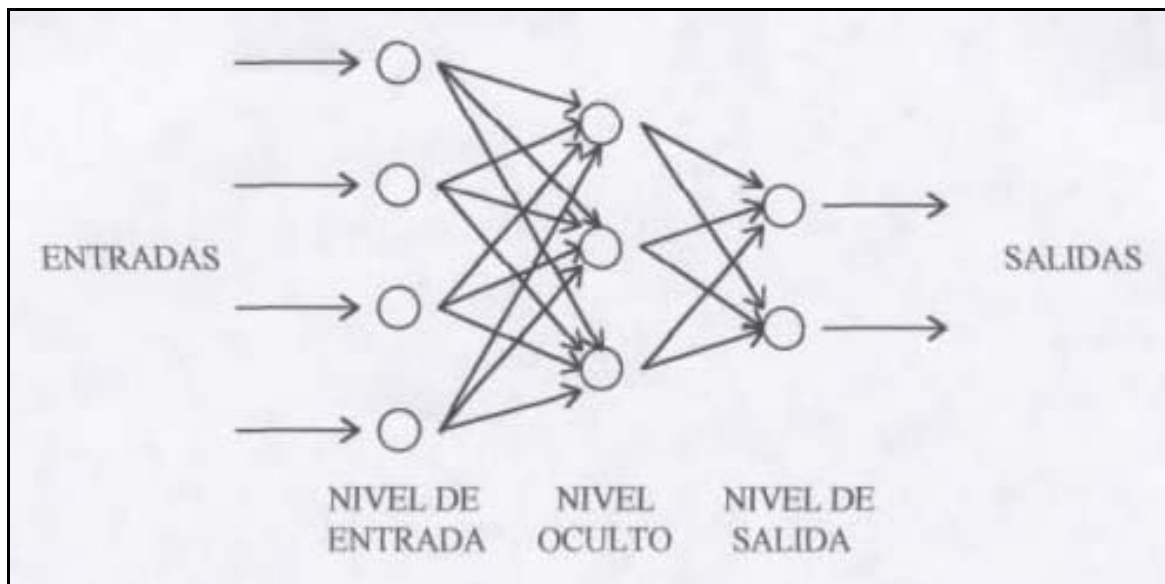


Figura 2. Representación de un Red Neuronal Artificial Multinivel.

Debido a su constitución y a sus fundamentos, las RNA presentan un gran número de características semejantes a la del cerebro (Andina, 1996):

- * Aprendizaje adaptativo: capacidad de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial.

- * Autoorganización: una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.

- * Tolerancia a fallas: en el cerebro mueren todos los días gran cantidad de neuronas sin afectar sensiblemente su funcionamiento.

- * Robustas: pueden trabajar con información borrosa, probabilística, con ruido o inconsistencia.

- * Altamente paralelas: el cerebro está formado por muchas neuronas interconectadas entre sí y es precisamente el comportamiento colectivo de toda ella, lo que caracteriza su forma de procesar la información.

Cada neurona en la red es un simple elemento de procesamiento (EP) o nodo, la cual recibe información de la capa anterior, la procesa y transmite la nueva información a la capa siguiente. Cada entrada tiene un peso relativo, lo que afecta el impacto de esa entrada. Es algo así como la variación de la intensidad sináptica de las neuronas biológicas, algunas entradas son "más importantes" que otras en la manera que ellas se combinan para producir un impulso (Nelson e Illingworth, 1991; Zhou y col., 1994).

Varias actividades importantes tienen lugar dentro del diseño del EP de la red neuronal, cuyos componentes básicos se muestran en la figura 3.

La función de suma (Σ), en la que las entradas (niveles de estimulación) y sus respectivos pesos (W) (fuerza de la sinapsis) son sumados y comparados con algún valor umbral para determinar la salida (impulso de la neurona). Si la suma de las entradas es mayor que el valor umbral, el EP genera una señal. Si la suma de las entradas es menor que el umbral, la señal no (o alguna señal inhibitoria) es generada. Ambos tipos de respuesta son significantes. La función de transferencia (T) se refiere a las ecuaciones requeridas para determinar el valor umbral y dentro de los distintos tipos que existen, la representada por una curva en forma de S o función sigmoidea, que se caracteriza por plantear un valor mínimo y máximo en las asíntotas, es frecuentemente la función de transferencia de elección.




Figura 3. Esquema de los componentes básicos de una Red Neuronal Artificial.

Los pesos son coeficientes adaptativos dentro de la red que determinan la intensidad de la señal de entrada. Se consideran como una medida de la fuerza de conexión. El peso inicial de un EP puede ser modificado en respuesta a varias entradas y de acuerdo a las propias reglas de la red (Nelson e Illingworth, 1991). Cuando los ejemplos son presentados, los pesos de las vías de conexión de las neuronas en una RNA serán ajustados para que pueda aprender la relación entre las entradas y salidas. Varias metodologías han sido desarrolladas para calcular o ajustar los pesos en una RNA de modo que pueda aprender a realizar tareas tales como asociación, discriminación, auto-organización, etc. Este procedimiento es llamado entrenamiento. Después del entrenamiento, cuando nuevas entradas son presentadas, las RNA pueden producir las salidas correctamente (Zhou, 1994; Zhou y col., 1994).

Clark (1997), explica lo anterior señalando que los sistemas neuronales artificiales son entrenados por la experiencia. Un sistema neuronal artificial es construido y luego simplemente es presentado con situaciones históricas de causa y efecto. El sistema entonces desarrolla o configura para sí mismo una representación interna de las reglas que lo gobernarán. Luego, después de que el sistema neuronal es entrenado, puede ser presentado a una situación hipotética para producir una predicción de los resultados de un evento real.

Es conocida la gran habilidad de las RNA para entender las características de un grupo de factores de entrada-salida, y la calidad de generalización que entregan cuando se les enfrenta a datos no presentados durante las etapas de entrenamiento, así como también se señala que una ventaja importante de las redes neuronales, es su habilidad para discriminar datos esenciales de los redundantes. El éxito de esta discriminación puede ser verificado por exposición de la red a datos "ruidosos" durante su validación. La verdadera ventaja de las RNA recae en su habilidad de entender los datos "ruidosos" los cuales no pueden ser fácilmente procesados de alguna otra manera. Esto hace pensar en aprovechar este tipo de tecnología para construir sistemas inteligentes de control (Fukada y Shibata, 1992, citado por Alvarez, 1994; Hourigan, 1994).

Clark (1997), con respecto a lo anterior señala que los sistemas neuronales artificiales son diferentes a otros programas de inteligencia artificial. Los programas de inteligencia artificial usan razonamiento deductivo al aplicar reglas conocidas a situaciones para producir las salidas. Cada nueva situación puede requerir que otra regla sea implementada. Los programas pueden llegar a ser bastantes grandes y complicados en un intento para dirigir todas las posibles situaciones. Los sistemas neuronales artificiales, sin embargo, automáticamente construyen asociaciones basadas sobre los resultados de situaciones conocidas. Para cada nueva situación, el sistema neuronal automáticamente se ajusta a sí mismo y eventualmente la generaliza.

Nelson e Illingworth (1991) señalan que las RNA se destacan por: la fuertes bases matemáticas, paralelismo inherente, almacenamiento del conocimiento, tolerancia a fallas, adaptabilidad y habilidades de reconocimiento-patrón.

Bases Matemáticas.

Las RNA son una de las pocas tecnologías relacionadas con inteligencia artificial que tienen un riguroso fundamento matemático. Fue en parte a los claros cimientos matemáticos y estadísticos de esta tecnología lo que atrajo la atención de la Academia Nacional de Ciencias cuando Hopfield presentó un trabajo en 1982, en el cual describe con claridad y rigor matemático una red a la que ha dado su nombre (Hilera y Martínez, 1995). En cambio otros sistemas expertos tienen mucho de la heurística (arte de inventar) u otras reglas, las cuales son mucho menos formales.

Algunas de las matemáticas son completamente sofisticadas, usando ecuaciones diferenciales, álgebra lineal y matrices de covarianza. Los pesos, sumas, funciones de transferencia y todos los algoritmos de aprendizaje tienen mucho de las matemáticas. Aunque las matemáticas están relacionadas al diseño, funcionamiento y sincronización de las RN, no es necesario ser un matemático para entender los principios básicos de operación.

Paralelismo Inherente.

Las RNA no sólo son estructuralmente paralelas, sino que la secuencia de procesamiento es paralela y simultánea. El esquema total del sistema así como los elementos de procesamiento individuales, combinan la teoría y la práctica en el rendimiento paralelo. Los EP en una capa están todos operando conjuntamente. El cálculo es distribuido sobre más de un EP y es realizado simultáneamente.

Aunque los computadores digitales han simulado este paralelismo, en realidad el hardware de la RNA realmente mejora las operaciones paralelas. Decisiones muy rápidas es posible y capaz de hacerlo en tiempo real. Hilera y Martínez (1995) explican que, aunque un ordenador realiza cálculos mucho más rápido que un ser humano, no es capaz de desarrollar procesos que éste realiza de forma sencilla (comprensión de una frase, analizar una imagen, reconocer un rostro, movimiento en un espacio determinado, etc.). Esto es debido a que el cerebro humano, para hacerlo, pone en marcha simultáneamente millones de neuronas.

Almacenamiento del Conocimiento.

El conocimiento dentro de una RN no es almacenada en memorias locales específicas, como en un computador convencional, sino que el conocimiento es *distribuido* a través del sistema; es la respuesta dinámica a las entradas y la arquitectura de la red. La memoria no solo es distribuida en una RN, también es *asociativa*.

Hilera y Martínez (1995), señalan que la información aprendida es almacenada en forma distributiva en los pesos asociados a la conexión entre los nodos como consecuencia de su aprendizaje, y que podría ser leído a la salida como respuesta a cierta información de entrada, cuyo comportamiento se conoce como memoria asociativa, es decir, cuando se aplica un estímulo, la red responde con una salida asociada a dicha información de entrada.

Una memoria asociativa es una aplicación de dato a dato, una abstracción matemática de la estructura familiar asociativa del aprendizaje humano y animal. Lo anterior se puede ilustrar con el siguiente ejemplo: los profesores pueden llegar a ser muy buenos leyendo la escritura a mano virtualmente ilegible de algunos de sus estudiantes. A pesar de las variaciones, distorsiones y omisiones, los humanos son buenos recuperando el modelo correcto. Así son las RNA.

Comparando este enfoque con un computador digital convencional usando la memoria de acceso aleatorio (RAM) y la memoria solo de lectura (ROM), cada hecho es almacenado en una localización única. Un hecho es recuperado proporcionando la dirección, aunque no hay relación particular entre el hecho y la dirección. Las RNA no trabajan de esta manera en lo absoluto, el conocimiento no es guardado en memorias localizadas, sino que está relacionado con la estructura de la red (cuanto de la señal de salida de un nodo está conectada a las señales de entrada de muchos otros nodos) y al peso relativo de cada nodo. El conocimiento consiste del estado global de la red en alguna condición de equilibrio, después de haber respondido a los patrones de entrada.

Las memorias asociativas tienen dos grandes beneficios: la habilidad para almacenar un gran número de patrones complejos (tales como plantillas de lenguaje, escenas visuales, movimientos de robots, comportamiento espacio-temporal, conducta social, y cosas por el estilo) y la habilidad de clasificar nuevos modelos para almacenar patrones rápidamente. Aunque los computadores convencionales por comparación, sobresalen por la alta velocidad de cálculos seriales, ellos hacen mal tal reconocimiento de patrones en un tiempo real.

Los EP responden a las entradas y las modificaciones de la red continúan hasta que un estado estable (una mínima energía) es alcanzado. Las redes no calculan la respuesta como los computadores convencionales lo hacen; a veces es más un asunto de memorizar las respuestas para las salidas dadas. Un número de buenos ejemplos visuales sirve para ilustrar una red yendo a través de un periodo de aprendizaje y finalmente la solución en relación a un patrón estable. Una red semejante fue creada usando un símbolo como Pac Man, el que come discos verdes y rojos. La mitad de los nodos procesa la entrada en un campo visual del Pac Man y la otra mitad genera los movimientos. Las reglas de aprendizaje del sistema refuerzan comer discos verdes y los discos rojos son estimados "no buenos".

Cuando la simulación comenzó el pequeño símbolo devoró cualquier disco a la vista. Pronto, sin embargo, hay un marcado descenso en el apetito por los discos rojos hasta que finalmente, ellos son completamente evitados. Al mismo tiempo, los discos verdes parecen tener más y más atractivo. La asociación no es sólo de contacto sino también de ver el objeto. El símbolo ha "aprendido" cuales discos son "buenos para comer" y cuales de "mal gusto". La conducta del sistema se estabiliza. Ahora, si el mal gusto de los discos rojos está fuertemente reforzado, evitar el "dolor" puede llegar a ser más importante que buscar el placer (de comer). Después de un número de repeticiones, el símbolo finalmente se devuelve y se esconde en la esquina al comienzo de la simulación. Sólo viendo uno de los discos rojos es estimulado a asegurarse de que esas odiosas cosas hay que evitarlas completamente.

Tolerancia a Fallos.

Las redes neuronales son extremadamente tolerantes a fallos. Ellas pueden aprender desde y realizar decisiones basadas en datos incompletos. Debido a que el conocimiento es distribuido a lo largo del sistema antes que establecido en una simple memoria localizada, un porcentaje de los nodos puede ser inoperativos sin cambios significantes en la conducta global del sistema. La resistencia del hardware a fallar es mucho más grande en una RNA que en un computador convencional, donde la falla del hardware es usualmente catastrófico.

Hilera y Martínez (1995), respecto a lo anterior, señalan que las RNA son los primeros métodos computacionales con la capacidad de tolerancia a fallos y la razón es que tienen su información distribuida en las conexiones entre neuronas, es decir no localizada, mientras que la mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos almacenan cada pieza de información en un espacio único, localizado y direccionable.

Hay dos aspectos distintos, según Hilera y Martínez (1995), respecto a la tolerancia a fallos: primero, las redes pueden aprender a reconocer patrones con ruido, distorsionados o incompletos, ésta es una tolerancia a fallos respecto a los datos. Segundo, pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red.

Adaptabilidad.

La adaptabilidad es la habilidad de una RNA completa a autoajustarse. Hilera y Martínez (1995), señalan que las RN son sistemas dinámicos autoadaptativos. Son adaptables debido a la capacidad de autoajustarse de los elementos procesales (neuronas) que componen el sistema. Son dinámicos, pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones.

La adaptabilidad es una de las características de las redes particularmente destacadas. Existen cuatro aspectos del proceso de adaptabilidad:

* Aprendizaje: es el nivel de un simple EP. El aprendizaje ocurre cuando los pesos de las conexiones son ajustados. Si se atribuye algo de memoria local a una neurona, podemos guardar resultados de cálculos previos y modificar los pesos usados.

Los cambios según Hilera y Martínez (1995), se refieren a destrucción, modificación y creación de conexiones entre neuronas. En los sistemas biológicos existe una continua creación y destrucción de conexiones. En los modelos de RNA, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero. De la misma manera, una conexión se destruye cuando su peso pasa a ser cero.

La habilidad de cambiar los pesos permite a la neurona modificar su comportamiento en respuesta a sus entradas, o aprender. Por ejemplo, si una RN identifica un perro como un gato, en sucesivas repeticiones, los pesos conectados que responden correctamente a las imágenes de un perro son reforzados; aquellos que responden a otras imágenes, como la de un gato son debilitadas hasta que ellas caen bajo el umbral. Los pesos tienen que ser ajustados hasta que todas las imágenes estén correctamente identificadas.

Cuando el ajuste de los pesos es realizado en capas anteriores desde las salidas de la red, el término Retropropagación ("*backpropagation*") es usado. Este es un importante concepto, debido a que la mayor cantidad de redes que se utilizan en la actualidad, emplean algoritmos de retropropagación.

* Autoorganización: es la modificación de muchos EP al mismo tiempo. Las sesiones de entrenamiento ejercitan las reglas para aprender como tienen lugar las modificaciones a lo largo de un sistema de red completo. Es como si las RN están desarrollando sus propios inventos mientras ellas van terminando las repeticiones. La red converge o concentra en una respuesta estable.

Según Hilera y Martínez (1995), las RN usan su capacidad de aprendizaje adaptativo para autoorganizar la información que reciben durante el aprendizaje y/o la operación. Mientras que el aprendizaje es la modificación de cada EP, la autoorganización consiste en la modificación de la red neuronal completa para llevar a cabo un objetivo específico.

Cuando las RN se usan para reconocer ciertas clases de patrones, ellas autoorganizan la información usada. Por ejemplo, la red llamada retropropagación, creará su propia *representación característica*, mediante la cual puede reconocer ciertos patrones (Hilera y Martínez, 1995).

* Generalización: es la habilidad de la red para responder a entradas a las que no ha sido expuesta antes. Las entradas pueden ser parciales o incompletas. La generalización tiene la habilidad de aprender y autoajustar una etapa más adelante. El sistema puede "hipotetizar" una respuesta.

Hilera y Martínez (1995), señalan que el sistema puede generalizar la entrada para obtener una respuesta. Esta característica es muy importante cuando se tienen que solucionar problemas en los cuales la información de entrada es poco clara; además, permite que el sistema dé una solución incluso cuando la información de entrada está especificada de forma incompleta.

* Entrenamiento: es la forma de aprender de la RN. Puede ser supervisado o no supervisado. El primero proporciona a la red ejemplos de una respuesta deseada; el último no provee ejemplos de salida, pero la red puede crear un grupo de características propias. Después del entrenamiento el sistema está listo para ser usado.

Reconocimiento de Patrones.

Existen muchos tipos de redes, y las diferencias en los modelos son debido principalmente al número de EP, como ellos están conectados y que leyes de aprendizaje presentan. Estas diferencias estructurales crean distintos paradigmas de aprendizaje por las cuales las redes son clasificadas. Algunas son buenas para reconocer, otras para detectar, clasificar, asociar, etc., toda una variedad de tareas puede ser emprendida, pero la mayoría de ellas relacionan de algún modo una habilidad para discernir patrones o modelos.

En general, un reconocimiento de patrones expresa para que se destaca mejor una RNA. Las redes tienen la habilidad de reconocer un conjunto de características previamente aprendidas, o ellas pueden seleccionar y generar su propio patrón de características en respuesta a una entrada.

Hilera y Martínez (1995), señalan que el reconocimiento o clasificación de patrones es una de las aplicaciones más extendidas de las redes neuronales, aprovechando la capacidad de generalización de éstas, las cuales pueden aprender una serie de modelos originales de diferentes clases, para posteriormente ser capaces de determinar la clase a la que pertenecen otras entradas distintas de los patrones aprendidos.

El término reconocimiento de patrones originalmente se refería a la detección de formas simples, tales como caracteres escritos a mano, mapas del tiempo y espectros del lenguaje. Sin embargo, un objetivo más ambicioso ha sido durante todo el tiempo implementar la *percepción artificial*; es decir, imitar las funciones de los sistemas sensoriales biológicos en su forma más completa (Hilera y Martínez, 1995).

Patrones incompletos: al igual que una persona puede reconocer a otra aún cuando ha visto sólo parte de su rostro, las RN son buenas en mirar un modelo parcial y predecir el entero. Llámelo intuición.

Las características de intuición y predicción permiten a las RNA resolver situaciones en las cuales la entrada puede ser confusa, incompleta, engañosa, ruidosa o ambigua, o puede aún tener algunos datos alterados o erróneos, por consiguiente dicha característica llega a ser altamente significativa.

Las RNA son consideradas actualmente como alternativa a los programas convencionales gracias a su capacidad de aprendizaje y adaptación. Se exploran paradigmas computacionales y se diseñan sistemas resistentes a errores, con lo que se presentan nuevos problemas y desafíos y un nuevo potencial en el diseño y control de sistemas adaptativos, agentes artificiales autónomos y vida artificial en general (Garzón, 1994).

Las RNA han sido aplicadas a un creciente número de problemas reales de considerable complejidad, por ejemplo, reconocimiento de patrones, clasificación de datos, predicción, etc. Su ventaja más importante radica en solucionar problemas que son demasiados complejos para las técnicas convencionales, problemas que no tienen un algoritmo específico para su solución, o cuyo algoritmo es demasiado complejo para ser encontrado. En general las RNA han sido claramente aceptadas como sistemas eficaces para el tratamiento de la información en muchas disciplinas, tales como: biología, medio ambiente, financieras y negocios, militares, tratamiento de textos y procesamiento de formas, energía, industria manufacturera, medicina y salud, ciencia e ingeniería, transporte y comunicaciones (Andina, 1996; Hilera y Martínez, 1995; Nelson e Illingmorth, 1991).

Las aplicaciones, así como las potenciales aplicaciones de las RNA, como muy bien las comparan Nelson e Illingmorth (1991), están apareciendo de repente como flores silvestres después de una lluvia de primavera.

Las RNA presentan un amplio espectro de aplicaciones, muchas ya descritas en la literatura, como por ejemplo: previsión del tiempo, predicción de riesgos crediticios, marketing, análisis de olor y aroma, predicción de consumo eléctrico y de gas, control de la línea de producción, desarrollo de medicamentos, control de calidad (Andina de la Fuente, 1996), característica de la escritura a mano (Andina, 1996; Nelson e Illingmorth, 1991), funcionalidad de las proteínas (Arteaga y Nakai, 1993), calidad de las manzanas (Bochereau y col., 1992), clasificación de señales electrocardiográficas (Hilera y Martínez, 1995), optimización del proceso de fabricación de queso y leche UHT (Hourigan, 1994; Norback, 1994; Zhou y col., 1994), reconocimiento de fonemas (Mora y col., 1996), evaluación del riesgo de hipotecas, sistema de detección de bombas, reconocimiento de palabras, revisión de motores de ventiladores, detección de minas submarinas (Nelson e Illingmorth, 1991), detección de fraudes en tarjetas de crédito (Piché, 1996), clasificación de productores agrícolas lecheros (Toledo, 1998), procesadores de imagen, detección de la corrosión, medición del espesor de la capa de grasa (Tuck, 1994), clasificación de planchas de aglomerados (Urrutia, 1997), etc.

La fábrica de equipos eléctricos Siemens, solucionó el problema de ruidos que presentaron los motores de ventiladores de los automóviles, al chequearlos completamente con una RNA, la que presentó más del 90 % de precisión (Nelson e Illingmorth, 1991).

Nelson e Illingmorth (1991), señalan que en Bendix Aerospace se diseñó una red neuronal capaz de reconocer y detectar minas submarinas; en aguas poco profundas, lo que es vital para la seguridad de la costa y los puertos. Distinguir entre las señales de sonar provenientes de minas, rocas y restos del suelo marino es difícil, y la RNA clasificó correctamente un 99 % de las señales.

Usando una RNA se creó un sistema de reconocimiento del lenguaje. Un inspector que realiza la revisión de un producto o de su proceso de fabricación, en lugar de anotar, le señala mediante un micrófono sus observaciones al computador, el que con un 99 % de precisión reconoce las palabras y las almacena como información específica, quedando sus manos libres para otras tareas (Nelson e Illingworth, 1991).

Urrutia (1997), utilizando una RNA para la interpretación de los datos obtenidos del análisis de superficie y cantos de planchas de aglomerados, para clasificar la calidad de éstas, concluyó que es posible analizar y clasificar dichas características con un 99 % de fiabilidad.

Otro estudio que demuestra la capacidad que ostentan las RNA, es el realizado por Toledo (1998), donde relacionó la calidad de clasificación (% de aciertos en datos de variación) obtenido con un método estadístico, que fue de un 87,5 %, en cambio con el método neuronal obtuvo en el peor de los casos un 95 % de aciertos.

Con todos los antecedentes expuestos, es posible visualizar las grandes ventajas que presentan las RNA sobre la computación tradicional, y es especialmente válido destacar que la neurocomputación aplicada correctamente es una poderosa herramienta destinada a resolver un sinnúmero de problemas, incluso aquellos que hasta ahora parecían no tener una solución factible, lo cual finalmente beneficiará a muchas disciplinas en los más variados ámbitos del quehacer humano.

En la siguiente tabla Nelson e Illingworth (1991), muestran que las redes neuronales artificiales son diferentes a los computadores convencionales.

Tabla 1. Comparación entre Software Tradicionales y Redes Neuronales Artificiales.

Software Tradicional	Redes Neuronales
Memoria solamente distributiva	Memoria tanto distributiva paralela como asociativa
El computador se vuelve inútil aún con una pequeña cantidad de daño en la memoria	Los computadores neuronales son tolerantes a fallas, debido a que la información está distribuida a lo largo del sistema
Entrada incompleta produce salida	Entrada incompleta no produce salida de resultados razonables
Se requiere formalizar una programación estructurada	Las redes neuronales presentan auto-organización

3.2 CELULAS SOMATICAS

Las células somáticas en la leche son de dos tipos: las células epiteliales de la ubre y los leucocitos de la sangre. Las células epiteliales presentes en la leche normal se deben a la constante reposición de las células en la glándula mamaria. Los leucocitos, especialmente los polimorfonucleares, cuya presencia es esencial para la defensa de la glándula mamaria contra la mastitis, pasan a la leche desde la sangre y su función es fagocitar bacterias (Paape, 1979; Schalm, 1971; Schultz, 1977).

La variación del número de células somáticas en la leche depende según Reichmuth (1975), de factores inflamatorios y no inflamatorios. Los inflamatorios o patológicos están dados por un organismo infectante. Los no inflamatorios o fisiológicos corresponden a variaciones diarias (Dijkman, 1975; Schultz, 1977), raza, edad, estado de lactancia, manejo del rebaño y factores ambientales (Agrees y col., 1976; Allore y col., 1996; Bodoh y col., 1975; Booth, 1998; Dohoo y Meek, 1982; Kennedy y col., 1976; Schukken y col., 1990).

Relacionando los factores que producen variación del contenido de células somáticas en la leche, no cabe duda que el más importante es la infección bacteriana, ya que la variación fisiológica del recuento celular es insignificante en relación al aumento provocado por la mastitis (Ledaal, 1976).

La importancia del recuento de células somáticas en leche cruda radica en el hecho que constituye un parámetro que expresa el grado de irritación de la glándula mamaria, con lo que se refleja indirectamente su estado sanitario (Booth, 1998; Deluyker y col., 1993; Harmon, 1994; Kruze, 1988), además de información sobre pérdidas en la producción láctea (Deluyker y col., 1993; Kruze, 1988; Miller y Paape, 1984; Pedraza y col., 1994; Wilson y col., 1996) y las modificaciones de la composición química de la leche (Casado y García, 1985; Kitchen, 1981; Kruze, 1988; Munro y col., 1984).

Kitchen y col. (1980), explicaron el aumento de las células somáticas en la leche. Según estos autores la leche de cuartos individuales de animales sanos contiene bajos niveles celulares, entre 50.000 - 200.000 cél/ml, correspondiendo a linfocitos, polimorfonucleares y células epiteliales en una proporción aproximada de 1 : 1,5 : 14. Frente a un cuadro de mastitis y dependiendo del grado de severidad de la infección y del tipo de microorganismo presente, los recuentos celulares van desde 200.000 a 5.000.000 cél/ml y la proporción de dichas células cambia al : 10 : 10, lo que indica que el aumento en el recuento de células somáticas se debe especialmente a la presencia de leucocitos polimorfonucleares.

La mastitis resulta en un aumento del recuento de células somáticas, porque la inflamación dilata las uniones intercelulares endoteliales y epiteliales, con la consiguiente migración de células inflamatorias desde la sangre al espacio extracelular y migración desde éste a la leche (Allore y col., 1996; Harmon, 1994).

En general se acepta que las vacas no infectadas tienen recuentos por debajo de 200.000 cél/ml y que la mayoría tendrá menos de 100.000 cél/ml la mayor parte de la lactancia (Natzke y col., 1972; Booth, 1998). Casado y García (1986), Pedraza (1995) y Zurita (1988), señalan que el funcionamiento normal de la glándula mamaria se expresa con recuentos inferiores a 250.000 cél/ml, mientras que con cifras superiores a 500.000 cél/ml son una señal de advertencia de probables alteraciones, como la presencia de mastitis.

3.3 PROPIEDADES FÍSICO-QUÍMICAS Y DE COMPOSICIÓN DE LA LECHE.

Alais (1985), define químicamente a la leche como "una emulsión de materia grasa que se encuentra formando glóbulos en un líquido que presenta similitudes con el plasma sanguíneo, el cual es una suspensión de materias proteicas en un suero, denominado suero lácteo. Este suero está constituido por una solución neutra que contiene principalmente lactosa y sales minerales".

La determinación de las propiedades físico-químicas y de composición de la leche, nos permite obtener información con respecto a la calidad de la leche analizada, las que son capaces de detectar alteraciones o fraudes en su composición (Schukken y col., 1992).

Las propiedades físico-químicas y de composición de la leche sufren modificaciones como consecuencia de la presencia de mastitis, lo que es manifestado por diversos investigadores.

Korhonen y Kaartinen (1995), señalan que las reacciones inflamatorias cambian la composición de la leche en términos de cantidad y calidad, y que varios fenómenos conectados con la inflamación ocurren simultáneamente:

1. la permeabilidad de los vasos sanguíneos aumenta resultando en el paso de iones y proteínas desde la sangre hacia la leche.
2. las células inflamatorias se mueven desde la sangre hacia la leche.
3. las células epiteliales, las cuales producen leche, llegan a ser menos eficientes; las células se rompen y las enzimas son liberadas.
4. la cantidad de leche disminuye.

Según Korhonen y Kaartinen (1995), cuando el grado de inflamación aumenta, la composición química de la leche se acerca cada vez más a la de la sangre debido a los componentes filtrados desde la circulación sanguínea a la glándula mamaria.

La tabla 2 muestra los cambios en cantidad de algunos de los componentes individuales de la leche, según Korhonen y Kaartinen (1995).

Tabla 2.- Efecto de la mastitis sobre la composición de la leche.

Componente	Contenido normal	Dirección y grado de cambio*
Grasa (%)	4.3	-
Proteína total (%)	3.3	-
caseína (mg/ml)	27.9	+++
proteína sérica (mg/ml)	8.5	-
Lactosa (%)	4.8	
Minerales (mg/ml)		
sodio	470	++
Potasio	1500	-
cloro	1030	+++
Enzimas		
catalasa (mmol O ₂ /min/ml)	0.08	++++
lactoperoxidasa (mg/ml)	0.02	+
lipasa (mg/ml)	1.5	++
Vitaminas (mg/ml)		
vitamina A	0.37	+/-
vitamina C	18	---

*Explicación:

+	=	10x aumenta	-	=	10% disminuye
++	=	11-100x aumenta	--	=	11-25 % disminuye
+++	=	01-1000x aumenta	---	=	6-75 % disminuye
++++	=	>1000x aumenta	----	=	75 % disminuye

Según Allore y col. (1996), como consecuencia de la mastitis, además del aumento del recuento celular en la leche, encontraron que disminuyen la grasa en un 10% y la lactosa y la caseína en un 15%.

Los cambios en algunas de las propiedades físicas de la leche se muestran en la tabla 3.

Tabla 3. Efecto de la mastitis sobre las propiedades físicas de la leche.

Propiedad	Dirección de cambio
pH	aumenta
Conductividad	aumenta
Viscosidad	aumenta
Acidez titulable	no cambia / disminuye
Densidad	disminuye

Fuente: Korhonen y Kaartinen (1995).

Kitchen (1981), señala que los cambios físico-químicos de la leche alteran la calidad del producto final. Un elevado contenido de ácidos grasos libres produce rancidez, además que dificulta la elaboración de productos fermentados. La disminución de la caseína y el pH alcalino disminuyen la producción de queso, y el aumento de sodio y cloruros afectan negativamente la coagulación prolongando el tiempo y elevando los costos de elaboración.

De vital importancia resulta la medición de las propiedades físico-químicas y de composición de la leche cruda realizada por la industria lechera, con el fin de obtener y asegurar los datos necesarios para diversos objetivos, como lo señala Jenness y col. (1974), tal información permite, por ejemplo, diseñar los equipos lecheros (capacidad calorífica, viscosidad, conductividad térmica, etc.), determinar la concentración de un componente o grupo de componentes (agua añadida, densidad para estimar sólidos no grasos, etc.), estimar la extensión de cambios físicos o químicos (viscosidad para apreciar agregación de micelas proteicas o glóbulos grasos, acidez titulable para seguir la acción bacteriana, etc.), obtener datos característicos de la leche y sus derivados, etc.

La gran ventaja que presentan los datos de las propiedades de la leche para los objetivos antes mencionados, se basa en la rapidez y simplicidad en la medición, así como también, en sus potencialidades para la automatización, cualidades cada vez más necesarias en todos los procesos industriales (Jenness y col., 1974).

3.4 OBJETIVO

Investigar la aplicación en la industria láctea de una herramienta computacional de última generación, como lo son las Redes Neuronales Artificiales, para clasificar la leche cruda recepcionada, según su contenido de células somáticas, a través de sus propiedades físico-químicas y de composición.

4. MATERIAL Y METODOS

4.1 ORIGEN Y PRETRATAMIENTO DE LOS DATOS

Los datos utilizados se obtuvieron de un estudio llevado a cabo por el Instituto de Ciencia y Tecnología de los Alimentos de la Universidad Austral de Chile, que corresponde a un proyecto FONDECYT cuyo título es: "Modelación de la variación estacional y regional de la leche cruda en las regiones VIH, IX y X".

Se utilizaron los resultados obtenidos del análisis de 192 muestras de leche cruda, realizados durante el período 1996 - 1997. Los análisis realizados a cada muestra corresponden a la determinación del contenido de células somáticas, mediante el método de Recuento Microscópico Directo, y a las siguientes propiedades físico-químicas y de composición:

- * Viscosidad
- * Coeficiente de dilatación volumétrica
- * Tensión superficial
- * Conductividad eléctrica
- * pH
- * Acidez titulable
- * Lactosa
- * Proteína del suero
- * Materia grasa
- * Sodio
- * Potasio

Una condición fundamental para trabajar con redes neuronales artificiales (RNA), es la variabilidad de los datos; por este motivo, es que la selección de las propiedades físico-químicas y de composición se realizó calculando, para cada una de ellas, el coeficiente de variación, ya que de todas las propiedades que son analizadas en una muestra de leche, algunas presentan poca variabilidad en sus resultados. Cuando se cumple tal condición los datos no son tomados en cuenta en la fase de entrenamiento de la RNA.

Como criterio de selección de las propiedades físicas, químicas y de composición que participaron en el ensayo, se estableció la eliminación de todas aquellas que presentaron un coeficiente de variación inferior al 5 %.

Los valores calculados para cada una de las propiedades señaladas fueron normalizados a fin de que sus datos queden comprendidos entre 0 y 1, para lo cual cada dato fue dividido por el valor máximo de cada análisis. Al dato identificado como valor máximo se le reconoce como Parámetro de Normalización. El procedimiento de normalización de datos es una etapa necesaria puesto que las funciones de transferencia utilizadas, corresponden al tipo sigmoidea, la cual sólo posee salidas comprendidas entre 0 y 1.

Es preciso dejar establecido que el parámetro señalado fue sometido a un leve proceso de ajuste, que consistió en representarlo con un nuevo valor ligeramente por encima del valor máximo mostrado por los datos originales. La razón de tal operación se basó en que el valor máximo normalizado debe ser inferior a 1.

En esencia las 192 muestras de leche cruda analizadas globalizaron un total de 2.304 datos, dado que cada muestra estaba constituida por 12 análisis diferentes.

En la presente investigación fueron ejecutadas dos etapas bien diferenciadas, que serán identificadas como etapa de Entrenamiento y etapa Experimental. La primera de las nombradas fue alimentada con un total de 2.040 datos correspondientes a 170 muestras, 1.870 pertenecientes a los 11 parámetros seleccionados y 170 a los recuentos celulares.

Por su parte la llamada etapa experimental consideró 242 datos provenientes de las 22 muestras de leche cruda multiplicado por 11 análisis realizados.

En resumen la red neuronal consistió de 11 entradas ("inputs") correspondientes a las propiedades seleccionadas. Como salidas ("outputs") 2 fueron consideradas, la primera en caso de un contenido de células somáticas mayor o igual a 300.000 cél/ml y la segunda si se tratase de un conteo inferior a 300.000 cél/ml.

El valor referencial recién mencionado, fue seleccionado atendiendo a que tal cifra representa el promedio del contenido celular en los más importantes productores de leche europeos. En éstos la materia prima que muestra un rango de 200.000 a 400.000 cél/ml, constituye la de mayor calidad (IDF, 1995).

4.2 ANALISIS DE LOS DATOS

Para el análisis y procesamiento de los datos se utilizó la base de datos del programa computacional Microsoft Excel versión 7.0 para Windows 95.

Para el entrenamiento de la red neuronal artificial se utilizó el software QWIKNET 2.15, el cual emplea el algoritmo de Retropropagación como arquitectura de aprendizaje.

Los parámetros empleados en el algoritmo de retropropagación fueron:

Tasa de aprendizaje : 0,1
 Momentum : 0,1
 Error de convergencia : 0,01
 N° de capas ocultas : 3

Capa oculta	N° de neuronas	Función de activación
1	5	sigmoidea
2	4	sigmoidea
3	3	sigmoidea

La figura 3 muestra la topología o arquitectura de la red neuronal utilizada en el presente estudio. La red es del tipo "feedforward" multinivel totalmente conectada, en el esquema por efecto de espacio y una mejor claridad en la representación, no aparecen todas las conexiones entre los nodos o EP de un nivel con los nodos del siguiente.




Figura 3. Red Neuronal de Retropropagación con 3 capas ocultas utilizada para la clasificación de la leche cruda.

5. RESULTADOS

Las 192 muestras de leche cruda a granel recepcionada en plantas lecheras, con sus propiedades físico-químicas y de composición seleccionadas y contenido de células somáticas, se presentan en el anexo 1.

Las propiedades seleccionadas con sus correspondientes valores promedio, desviación estándar y coeficiente de variación, se presenta en la siguiente tabla.

Tabla 4. Valores promedio, desviación estándar y coeficiente de variación para cada una de las propiedades físico-químicas y de composición seleccionadas.

Propiedad	Promedio	Desv. Estándar	Coef. Variación
Viscosidad (cP)	1,76	0,11	0,06
Dilatometría (l/C°)(hasta20°C)	3,66E-03	1.41E-03	0,39
Tensión Superficial (dinas/cm)	38,72	3,21	0,08
Conductividad (mS)	4,96	0,39	0,08
PH	6,51	0,37	0,06
Acidez Titulable	18,75	2,22	0,12
Lactosa (gr/100ml)	4,91	0,26	0,05
Proteína del Suero (%)	0,68	0,09	0,13
Sodio (gr/l)	0,34	0,05	0,15
Potasio (gr/l)	1,67	0,19	0,11
Materia Grasa (%)	3,53	0,25	0,07

Las 11 propiedades seleccionadas corresponden a las entradas ("inputs") de la red neuronal artificial. El contenido de células somáticas representa las salidas ("outputs"), en donde se estableció la siguiente norma: una salida con un valor de 0,9 significa un contenido celular mayor o igual a 300.000 cél/ml, y la otra salida con un valor de 0,1 indica un contenido celular menor a 300.000 cél/ml (anexo 2).

Una vez que se seleccionaron las propiedades, se procedió a normalizar todos los datos que se utilizaron, para que sus valores queden comprendidos entre 0 y 1, tanto aquellos empleados para el entrenamiento de la RNA (anexo 3), como para medir su poder de predicción (anexo 4).

La normalización de los datos se llevó a cabo dividiendo cada uno de los valores por el parámetro de normalización, que corresponde al valor máximo de cada análisis.

En la siguiente tabla se presentan las propiedades seleccionadas con sus respectivos parámetros de normalización.

Tabla 5. Parámetro de Normalización para cada una de las propiedades físico-químicas y de composición seleccionadas.

Propiedad	Parámetro de Normalización
Viscosidad (cP)	2,78
Dilatometría (l/C°)(hasta20°C)	0,01
Tensión Superficial (dinas/cm)	45,80
Conductividad (mS)	6,23
pH	7,00
Acidez Titulable	28,90
Lactosa (gr/100ml)	5,60
Proteína del Suero (yo)	1,20
Sodio (gr/lit)	0,57
Potasio (gr/lit)	3,22
Materia Grasa (%)	4,34

Una vez que ha sido entrenada la red neuronal artificial, se procede a ingresar los datos de prueba, que corresponden a las propiedades físico-químicas y de composición de 22 muestras de leche cruda a granel.

En la tabla 6 se presentan los valores a predecir y aquellos que se obtuvieron de las predicciones realizadas por la red neuronal artificial, del contenido de células somáticas en leche de las 22 muestras de prueba.

Los valores con asterisco corresponden a las muestras de leche cruda, cuyo contenido de células somáticas fue erróneamente predecido por la red neuronal artificial.

Tabla 6. Predicción del contenido de células somáticas en leche cruda de las 22 muestras de prueba.

N° de muestra	Cél. Somáticas	Valor a predecir	Predicción
1	279.511	0,1	0,1
2	526.976	0,9	0,9
3	331.178	0,9	0,9
4	551.266	0,9	0,9
5	378.682	0,9	0,1*
6	327.996	0,9	0,9
7	312.291	0,9	0,9
8	291.017	0,1	0,1
9	397.432	0,9	0,9
10	400.730	0,9	0,8
11	183.727	0,1	0,1
12	179.481	0,1	0,2
13	183.825	0,1	0,1
14	184.561	0,1	0,1
15	357.572	0,9	0,9
16	283.275	0,1	0,8*
17	291.445	0,1.	0,9*
18	645.882	0,9	0,9
19	308.133	0,9	0,9
20	184.604	0,1	0,9*
21	152.696	0,1	0,1
22	346.713	0,9	0,9

En el gráfico 1, se presenta la distribución de los valores a predecir y las predicciones del contenido celular (normalizado), de las 22 muestras de leche cruda utilizadas para probar el poder predictivo de la red neuronal artificial. Los valores se obtuvieron de la tabla 6.

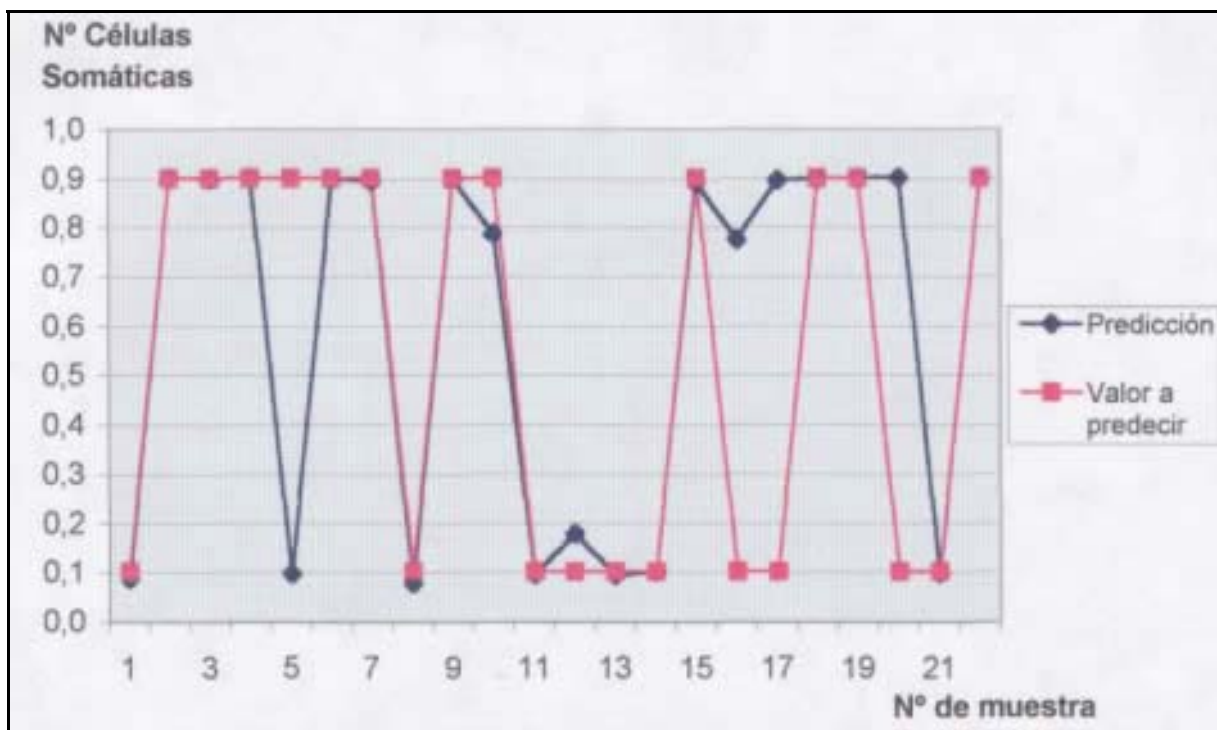


Gráfico 1. Distribución de las predicciones del contenido de células somáticas en leche cruda.

En la tabla 7, se presenta el resultado porcentual y absoluto de la predicción del contenido celular de las 22 muestras de leche cruda.

Tabla 7. Distribución porcentual y absoluta de las predicciones del contenido de células somáticas en leche cruda.

Predicción	Nº de muestras	%
acertada	18	81,8
errónea	4	18,2
Total	22	100,0

En la tabla anterior, se observa que la red neuronal artificial presenta casi un 82 % de confiabilidad para predecir el contenido de células somáticas en leche cruda, a partir de sus propiedades físico-químicas y de composición.

6. DISCUSION

En primer término, es preciso recordar que la presente investigación se basó en la utilización de una metodología, basada en las Redes Neuronales Artificiales (RNA), aplicadas a la clasificación de la leche cruda, tomando en consideración sus propiedades fisico-químicas y de composición. En la literatura el método experimental utilizado no muestra aplicaciones similares por lo que los resultados logrados representan las primeras informaciones sobre la materia. Sí las referencias bibliográficas exhiben experiencias en torno a otros tipos de productos y a otras aplicaciones.

De acuerdo a lo observado en la tabla 6, del total de 22 muestras que participaron en la etapa experimental propiamente tal, 18 de ellas fueron correctamente pronosticadas, en cuanto a su contenido celular. Lo recién señalado indica que el nivel de confiabilidad corresponde prácticamente a 82 %, lo cual puede ser considerado como aceptable al tomar en cuenta las limitaciones de la red empleada.

Se tiene conocimiento de la existencia en el mercado de software para los mismos fines, capaces de entregar niveles de confiabilidad más elevados, material que no estuvo al alcance de la presente investigación fundamentalmente por razones de índole económico. La utilización de software más perfeccionados en cuanto a su ingeniería y los procedimientos o algoritmos que utiliza para el procesamiento de la información, le permiten seleccionar de entre todas las variables y valores que dispone, los datos más apropiados para lograr un óptimo nivel de aprendizaje durante su entrenamiento y permitir así incrementar el nivel de predicción logrado en este estudio hasta un 100 %.

6.1 CONCLUSIONES

- 1.- Es posible predecir el contenido de células somáticas de una muestra de leche cruda a partir de sus propiedades fisico-químicas y de composición, aplicando las Redes Neuronales Artificiales.
- 2.- El nivel de confiabilidad logrado en la presente investigación alcanzó a 81,8 %.
- 3.- Mediante el empleo de un software de redes neuronales artificiales más potente y sofisticado, que poseen algoritmos más complejos, con bases matemáticas y estadísticas más avanzadas para lograr un mayor poder de predicción, se considera posible alcanzar niveles de confiabilidad mucho más elevados, incluso de hasta un 100 %.

4.- La determinación del contenido de células somáticas a partir de las propiedades físico-químicas y de composición de la leche, utilizando las Redes Neuronales Artificiales, puede permitir a los laboratorios de análisis y de control de calidad, disponer de una nueva herramienta, producto del avance de la tecnología computacional. Lo señalado hará posible una mayor eficiencia al disminuir el tiempo y los costos que involucra el conteo celular mediante los métodos tradicionales.

5.- Basado en los resultados logrados mediante la aplicación de las Redes Neuronales Artificiales, se considera trascendente ejecutar nuevas investigaciones en torno a la utilización de tal herramienta dentro del quehacer de la industria lechera, que permitan analizar y evaluar la calidad, tanto de la leche cruda como de sus subproductos en un tiempo real.

7. BIBLIOGRAFIA

- AGREES, E.H., G.W. BODOH, W.J. BATISTA, L.H. SCHULTZ y R.D. JOHNSTON Jr. 1976. Variation in somatic cell count in dairy herd improvement milk sample. J. Dairy Sci., 59: 119.
- ALAIS, C. 1985. Ciencia de la leche. IV edición. Ed. Reverte S.A. Barcelona, España. 873 p.
- ALLORE, H.G., P.A. OLTENACU y H.N. ERB. 1996. Effects of season, herd size and geographic region on the composition and quality of milk in the Northeast. J. Dairy Sci., 80: 3040 - 3049.
- ALVAREZ, H.D. 1994. Redes Híbridadas-No Difusas y su uso en control inteligente. Memorias del Primer Congreso Colombiano de Neurocomputación. Santa Fe de Bogotá, pp 1 - 14.
- ANDINA, D. 1996. Conceptos básicos sobre redes neuronales artificiales. [Http://www.ge.ssr.upm.es/inves/neural/ann2/concepts/concepts.htm](http://www.ge.ssr.upm.es/inves/neural/ann2/concepts/concepts.htm).
- ARTEAGA, G.E. y S. NAKAI. 1993. Predicting protein functionality with artificial neural networks: foaming and emulsifying properties. J. Food Sci., 58: 1152 - 1156.
- BOCHEREAU, L., P. BOURGINE y B. PALACIOS. 1992. A method for prediction by combining data analysis and neural networks: application to prediction of apple quality using near infra-red spectra. J. Agric. Engineering Res., 51: 207 - 216.
- BODOH, G.W., W.J. BATTISTA y L.H. SCHULTZ. 1975. Variation in somatic cell counts in dairy herd. Improvement samples. J. Dairy Sci., 58 (5): 753.
- BOOTH, J. M. 1998. Recuento de células somáticas como indicador de mastitis. II Jornada CONAMASCAL: Control de mastitis y calidad de leche. Abril, 1998. Temuco, Osorno, Puerto Varas, Chile, pp. 13-18.
- CASADO, P. y J. GARCÍA. 1985. Calidad de leche. Ind. Lácteas Españolas. 81:1- 300.
- CASADO, P. y J. A. GARCÍA. 1986. Mastitis y calidad de la leche. Hojas divulgadoras N° 2. Ministerio de Agricultura, Pesca y Alimentación. España.
- CLARK, D. W. 1997. An introduction to neural networks. <http://members.home.net/neuralnet/introtonn/index.htm>

- DELUYKER, H.A., J.A., GAY y L.D. WEAVER. 1993. Interrelationships of somatic cell count, mastitis and milk yield in a low somatic cell count herd. *J. Dairy Sci.*, 76: 3445 - 3452.
- DIJKMAN, A. J. 1975. Cells in milk. *N. Milk Dairy J.* 29(2): 99 - 103.
- DOHOO, I.R. y A.H. MEEK. 1982. Somatic cell counts in bovine milk. *Can. Vet. J.*, 23: 119-125.
- GANONG, W. 1992. Fisiología médica. Editorial El Manual Moderno, S. A. México. 744 pp.
- GARZÓN, M. 1994. Evolutionary computation: evolution in evolution. Memorias del Primer Congreso Colombiano de Neurocomputación. Santa Fe de Bogotá. D.C. pp 43 - 51.
- HARMON, R.J. 1994. Physiology of mastitis and factors affecting somatic cell counts. *J. Dairy Sci.*, 77:2103.
- HILERA, J. y V. MARTÍNEZ. 1995. Redes Neuronales Artificiales: Fundamentos, Modelos y Aplicaciones. Editorial Addison - Wesley Iberoamericana.
- HOURIGAN, J.A. 1994. Artificial neural networks in the dairy industry: Introduction and Overview. *Aust. J. Dairy Technol.*, 49: 110 - 111.
- IDF, INTERNATIONAL DAIRY FEDERATION. 1995. " Milk Payment Systems for Ex-Farm Milk". Bulletin of the IDF N° 305/1995.
- JENNES, R., W. SHIPE Jr. y J. SHERBON. 1974. Physical Properties of Milk. En: Webb, B., A. Johnson y T. Alford. Fundamentals of dairy chemistry. 2^a edition. The AVI Publishing Company, Inc. Westport, Connecticut. 929.
- KENNEDY, W., J.E. MOXLEY y B.R. DOWNEY. 1976. The effects of stage lactation on somatic cell count. *Can. J. Anim. Sci.*, 56 (4): 829 - 850.
- KITCHEN, B. 1981. Review of the progress of dairy science: bovine mastitis: milk compositional changes and related diagnostic test. *J. Dairy Res.*, 48: 167 - 188.
- KITCHEN, B., G. MIDDLETON, I. DURWARD, R. ANDREWS y M. SALMON. 1980. Mastitis diagnostic test to estimate mammary gland epithelial cell damage. *J. Dairy Sci.*, 63 (6): 978 - 983.
- KORHONEN, H. y KAARTINEN, L. 1995. Changes in the composition of milk induced by mastitis. En: Sandholm, M., T. Honkanen-Buzalski, L. Kaartinen y S. Pyörälä. The Bovine Udder and Mastitis. Universidad de Helsinki, Helsinki, 1995. 312 p.

- KRUZE, J. 1988. Mastitis: efectos en la producción y calidad de la leche. Primer Seminario de Producción Animal (Bovinos de carne y leche). INIA. Estación Experimental Carillanca. Consejo Regional de Transferencia Tecnológica, EX Región, Temuco, Chile.
- LEDAAL, S. 1976. Cell count determination as a quality test for raw milk. Nor. Veterinärstidsskr., 88 (2): 102 - 105. Original no disponible, obtenido de Dairy Sci. Abstr. 39 (1): 60. 1977.
- MILLER, R.H. y M.J. PAAPE. 1984. Relationships between milk somatic cell count and milk yield. Annual Meeting National Mastitis Council, 18, Louisville, pp 60.
- MORA, B., O. GUALDRON y Y. TORRES. 1996. Reconocimiento de fonemas mediante el uso de redes neuronales. Memorias del Primer Congreso Colombiano de Neurocomputación. Santa Fe de Bogotá. D.C. pp 109 - 124.
- MUNRO, G., P. GRIEVE y B. KITCHEN. 1984. Effects of mastitis on milk yield, milk composition, processing properties and yield and quality of milk products. Austr. J. Dairy Technol 39: 7 - 16.
- NATZKE, R. P., R.W. EVERETT y D.S. POSTLE. 1972. Normal milk somatic cell counts. J. Milk Food Technol. 35: 261 - 263.
- NELSON, M. e T. ILLINGWORTH. 1991. A Practical Guide to Neural Nets. Addison-Wesley Publishing Company, Inc. 344p.
- NORBACK, J. P. 1994. Applying neural nets in food manufacturing. Aust. J. Dairy Technol., 49: 114-116.
- PAAPE, M. 1979. Somatic cell count in milk. Nature and action. Annual Meeting National Mastitis Council, 18, Louisville, pp 5 - 24.
- PEDRAZA, C. 1995. Sanidad mamaria y calidad de leche. En: F. Lanuza Ed. Seminario Calidad de leche bovina. 23 y 24 de Junio, Colegio Médico Veterinario de Chile, Consejo Regional Osorno, Chile.
- PEDRAZA, C., H. AGÜERO, M. GÓMEZ, E. JAHN y F. LANUZA. 1994. Relación entre la concentración de células somáticas y producción de leche, determinada en 5 rebaños lecheros de Chile. Agricultura Técnica (julio-septiembre, 1994) 54 (3): 259 - 267. Instituto de Investigaciones Agropecuarias.
- PICHE, S.W. 1996. Credit cards fraud detection using neural networks. Memorias del Primer Congreso Colombiano de Neurocomputación. Santa Fe de Bogotá. D.C. pp 153 - 160.

- REICHMUTH, J. 1975. Somatic cell counting. Interpretation of results seminar on mastitis control. In : International Dairy Federation. Proceeding of Semimnar on Mastitis Control 1975. Document 85: 96 - 97.
- SCHALM, O. 1971. Bovine Mastitis. Editorial Lea & Febiger, Philadelphia, U.S.A.
- SCHUKKEN, Y.H., J. BURMAN, A. BRAND, D. VAN DER GEER y F.J. GROMMERS. 1990. Population dynamics of bulk milk somatic cell counts. J. Dairy Sci., 73: 1343 - 1350.
- SCHUKKEN, Y.H., K. LESLIE, A. WEERSINK y S. MARETIN. 1992. Ontario, bulk milk somatic cell count reduction program. 1. Impact on somatic cell counts and milk quality. J. Dairy Sci., 75: 3352 - 3358.
- SCHULTZ, L.H. 1977. Somatic cells in milk-physiological aspects and relationship to amount and composition of milk. J. Food Prot.,40 (2): 125-131.
- TOLEDO, M. 1998. Clasificación Neuronal y Estadística de Unidades Productivas Agropecuarias Relacionadas con centro de Gestión Empresarial del Área de Pitrufoquén. Tesis, Facultad de Computación e Informática, Universidad Austral de Chile, Valdivia, Chile.
- TUCK, D. 1994. Neurocomputing: Industrial Applications. Aust. J. Dairy Technol 49:112-114
- URRUTIA, J.E. 1997. Investigación y desarrollo de un prototipo a escala para la calibración de planchas de aglomerados a través del procesamiento de imágenes y la aplicación de redes neuronales. Tesis, Facultad de Ciencias de la Ingeniería, Universidad Austral de Chile, Valdivia, Chile.
- WILSON, D., R. GONZÁLEZ y H. DAS. 1996. Bovine mastitis pathogens in New York and Pennsylvania : Prevalence and effects on somatic cell count and milk production. J. Dairy Sci., 80: 2592 - 2598.
- ZHOU, W. 1994. An introduction to artificial neural networks (ANN). Aust. J. Dairy Technol 49: 111-112.
- ZHOU, W., K. KAILASAPATHY, D.G. LAING y M. RAMACHANDRAN. 1994. Application of artificial neural networks (ANN) in UHT milk processing. Aust. J. Dairy Technol., 49: 117.
- ZURITA, L. 1988. Mastitis subclínica, grave problema económico en lecherías. Chile Agrícola. 13: 326 - 328.

8. ANEXOS.

Anexo 1.- Propiedades físico-químicas y de composición y contenido de células somáticas de las 192 muestras de leche cruda.-

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG	CS
1	1,860	4,7E-03	37,596	4,770	6,595	19,950	4,915	0,700	0,355	1,600	3,800	354.056
2	1,855	5,0E-03	37,340	4,470	6,695	19,950	5,146	0,640	0,365	1,750	3,700	456.941
3	1,739	5,8E-03	35,920	4,660	6,695	19,000	4,954	0,820	0,355	1,650	3,300	503.711
4	1,709	4,4E-03	37,640	4,815	6,400	20,900	4,954	0,650	0,350	1,600	3,500	438.421
5	1,903	3,0E-03	36,310	4,550	6,675	20,190	5,146	0,700	0,375	1,625	3,300	583.641
6	1,664	3,8E-03	36,290	4,605	6,395	19,950	4,954	0,710	0,355	1,580	3,000	558.168
7	1,744	3,6E-03	35,010	4,670	6,700	20,190	5,069	0,630	0,355	1,600	3,500	388.376
8	1,786	3,9E-03	36,760	4,665	6,670	18,050	4,762	0,690	0,381	1,463	3,650	263.729
9	1,920	7,1E-03	35,830	4,615	6,690	17,100	4,781	0,740	0,365	1,625	3,875	403.681
10	1,744	5,1E-03	36,570	4,690	6,730	16,865	4,915	0,680	0,365	1,587	3,225	234.855
11	1,850	2,2E-03	36,600	4,640	6,730	16,390	4,723	0,680	0,323	1,400	3,550	383.450
12	1,916	4,4E-03	36,370	4,785	6,600	18,050	4,819	0,670	0,330	1,525	3,625	307.030
13	1,866	4,3E-03	36,660	4,580	6,760	19,950	4,934	0,600	0,250	1,650	3,650	428.168
14	1,943	4,8E-03	36,974	4,635	6,710	16,150	4,877	0,700	0,320	1,463	3,750	397.857
15	1,967	5,4E-03	39,937	4,600	6,640	17,100	4,532	0,660	0,330	1,590	3,800	315.739
16	2,770	3,7E-03	37,150	4,660	6,685	23,000	4,760	0,700	0,376	3,200	3,550	406.232
17	1,729	5,3E-03	34,330	4,450	6,765	19,500	4,840	0,700	0,550	3,075	3,700	308.489
18	1,670	3,3E-03	35,830	4,690	6,735	17,950	4,840	0,700	0,281	1,590	3,500	341.781
19	1,805	3,5E-03	35,680	4,920	6,750	18,050	4,880	0,580	0,330	1,610	4,100	319.486
20	1,733	3,5E-03	35,700	4,810	6,740	18,050	4,950	0,380	0,281	1,560	3,900	338.398
21	1,760	3,8E-03	41,620	4,545	6,720	18,050	4,950	0,660	0,330	1,625	3,935	474.410
22	1,670	4,9E-03	38,470	4,540	6,725	18,050	4,990	0,660	0,280	1,525	3,450	344.387
23	1,750	3,8E-03	40,330	4,600	6,740	17,100	4,490	0,710	0,287	1,525	3,400	361.085
24	1,837	8,3E-03	41,330	4,740	6,710	18,050	4,670	0,890	0,275	1,500	3,600	328.053
25	1,874	4,7E-03	38,180	4,570	6,735	18,050	4,780	0,670	0,356	1,550	3,700	329.180
26	1,789	3,7E-03	44,380	4,605	6,770	17,100	4,420	0,660	0,330	1,425	3,500	279.165
27	1,741	4,8E-03	38,660	4,855	6,575	23,940	4,560	0,730	0,250	1,425	3,525	430.811
28	1,596	3,3E-03	38,840	4,810	6,465	19,950	4,490	0,650	0,350	1,340	3,700	345.673
29	1,662	3,5E-03	40,930	4,780	6,690	20,900	4,460	0,660	0,340	1,375	3,625	500.671
30	1,590	3,7E-03	40,720	4,650	6,695	17,290	4,640	0,640	0,320	1,437	3,450	309.831
31	1,662	4,1E-03	38,840	4,495	6,675	16,620	4,640	0,660	0,340	1,550	3,690	477.636
32	1,638	4,4E-03	39,960	4,525	6,630	17,690	4,640	0,690	0,350	1,647	3,800	367.154
33	1,667	3,1E-03	43,470	4,550	6,635	21,850	4,430	0,650	0,375	1,600	3,700	431.918
34	1,686	2,8E-03	41,810	5,100	6,120	17,860	4,020	0,670	0,320	1,640	3,850	222.520
35	1,756	3,5E-03	41,770	4,735	6,625	18,050	4,820	0,650	0,413	1,780	3,400	232.420

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG	CS
36	1,773	3,8E-03	38,170	4,415	6,725	18,050	4,860	0,640	0,463	1,800	3,500	299.033
37	1,727	3,5E-03	41,191	4,650	6,845	18,050	5,520	0,710	0,413	1,800	3,500	232.956
38	1,745	3,1E-03	40,640	4,600	6,805	18,050	5,570	0,750	0,375	1,750	3,800	341.557
39	1,745	4,4E-03	38,980	4,550	6,770	18,050	5,340	0,720	0,413	1,800	4,000	429.611
40	1,952	5,0E-03	42,310	4,360	6,790	16,620	5,520	0,710	0,450	1,550	4,325	346.382
41	1,808	3,6E-03	41,030	4,930	6,785	17,100	5,290	0,690	0,440	1,460	3,500	128.692
42	1,756	4,1E-03	39,330	5,120	6,685	17,100	5,060	0,620	0,330	1,575	3,700	301.458
43	1,739	4,6E-03	40,870	4,650	6,770	20,900	5,020	0,630	0,430	1,630	3,500	331.303
44	1,831	4,9E-03	40,490	4,550	6,740	23,940	5,130	0,620	0,430	1,630	3,625	360.724
45	1,675	4,0E-03	39,820	4,770	6,660	19,950	5,060	0,630	0,400	1,550	3,500	363.401
46	1,837	4,6E-03	38,680	4,570	6,780	17,680	5,250	0,600	0,360	1,750	3,675	248.801
47	1,768	4,7E-03	42,330	4,570	6,835	16,910	5,150	0,720	0,330	1,500	4,000	415.410
48	1,802	5,0E-03	41,650	4,720	6,760	18,050	5,130	0,820	0,330	1,590	3,600	263.516
49	1,641	3,7E-03	41,370	5,150	6,920	21,850	5,090	0,750	0,380	1,620	3,400	375.608
50	1,722	3,8E-03	40,050	4,560	6,600	19,070	5,100	0,730	0,340	1,600	3,450	550.606
51	1,773	3,7E-03	44,540	4,725	6,700	18,170	5,080	0,680	0,330	1,600	3,125	313.530
52	1,762	3,6E-03	43,320	4,880	6,710	17,470	5,050	0,680	0,375	1,600	3,525	704.119
53	1,727	2,8E-03	42,910	4,710	6,790	17,420	5,110	0,700	0,288	1,613	3,525	547.096
54	1,733	5,0E-03	44,160	4,715	6,710	17,670	5,090	0,740	0,340	1,750	3,600	398.935
55	1,710	3,6E-03	45,070	4,710	6,670	17,470	5,160	0,700	0,330	1,650	3,475	358.277
56	1,785	9,0E-03	45,780	4,640	6,740	17,170	5,090	0,730	0,303	1,625	3,525	436.655
57	1,710	7,5E-03	43,930	4,620	6,620	17,670	4,980	0,670	0,356	1,775	3,175	463.314
58	1,739	5,1E-03	43,570	4,655	6,715	18,680	5,110	0,690	0,330	1,550	3,600	313.729
59	1,739	4,1E-03	43,230	4,175	6,710	18,180	5,070	0,690	0,330	1,587	3,525	389.613
60	1,699	7,3E-03	42,050	4,970	6,285	19,690	4,860	0,640	0,340	1,887	3,200	700.597
61	1,727	6,1E-03	44,770	4,840	6,670	18,680	5,160	0,620	0,340	1,625	3,500	331.658
62	1,768	4,0E-03	40,890	4,560	6,745	21,000	4,950	0,670	0,450	1,587	3,800	520.380
63	1,773	4,2E-03	42,030	4,645	6,735	17,800	4,940	0,700	0,340	1,587	3,400	272.183
64	1,722	4,1E-03	42,400	4,690	6,660	17,200	5,050	0,700	0,340	1,750	3,400	290.054
65	1,831	6,9E-03	41,180	4,910	6,185	20,200	4,790	0,670	0,348	1,613	3,900	749.260
66	1,791	4,1E-03	43,570	4,395	6,640	20,500	5,110	0,690	0,395	1,701	3,500	400.955
67	1,768	5,0E-03	43,850	4,765	6,695	20,000	5,330	0,690	0,350	1,200	3,700	374.791
68	1,711	3,4E-03	40,220	4,770	6,670	19,500	5,090	0,620	0,348	1,710	3,300	402.959
69	1,722	2,5E-03	44,110	4,700	6,765	18,500	5,250	0,710	0,360	1,675	3,625	323.507
70	1,785	3,0E-03	42,390	4,720	6,750	19,200	5,210	0,700	0,336	1,638	3,500	351.145
71	1,808	1,4E-03	42,730	4,750	6,710	20,000	5,160	0,710	0,335	1,662	3,350	373.296
72	1,837	4,1E-03	42,500	4,780	6,730	18,000	5,180	0,690	0,300	1,633	3,300	450.079
73	1,739	4,1E-03	42,670	4,910	6,460	20,500	5,010	0,710	0,370	1,612	3,600	484.640
74	1,739	4,1E-03	41,270	4,565	6,730	17,500	5,190	0,730	0,226	1,563	3,350	200.920
75	1,693	5,0E-03	44,790	4,710	6,650	19,000	5,030	0,570	0,328	1,600	3,300	395.120
76	1,808	2,1E-03	41,650	4,930	6,100	25,000	5,070	0,710	0,365	1,750	3,200	472.256
77	1,822	4,1E-03	40,910	4,640	6,740	20,500	5,250	0,680	0,306	1,575	3,350	237.511
78	1,768	6,2E-03	39,120	4,690	6,690	21,000	5,170	0,720	0,340	1,625	3,300	294.254

Nº	V	D	TS	C	pH	AT	L	PS	S	P	MG	CS
79	1,791	2,1E-03	42,250	4,770	6,255	20,000	4,960	0,710	0,367	1,600	3,275	360.529
80	2,015	3,8E-03	39,190	4,520	6,710	17,000	4,840	0,710	0,350	1,625	3,725	508.234
81	1,819	3,2E-03	40,550	4,580	6,735	17,200	5,140	0,730	0,343	1,678	3,225	194.233
82	1,719	4,1E-03	39,580	4,790	6,310	18,500	5,120	0,630	0,356	1,625	3,325	366.179
83	1,756	5,5E-03	41,470	4,680	6,460	18,000	4,970	0,670	0,356	1,725	3,275	279.136
84	1,798	2,8E-03	38,640	4,970	5,780	23,500	5,050	0,560	0,306	1,625	3,250	421.255
85	1,831	4,1E-03	39,630	4,550	6,730	16,000	5,120	0,550	0,350	1,700	3,500	424.876
86	1,876	5,0E-03	40,170	4,620	6,670	18,000	5,000	0,690	0,356	1,650	3,375	299.911
87	1,823	5,8E-03	41,170	4,490	6,640	17,000	5,130	0,670	0,331	1,625	3,300	269.803
88	1,774	5,0E-03	39,210	4,420	6,760	16,000	5,060	0,650	0,367	1,750	3,500	224.682
89	1,782	4,1E-03	38,190	4,520	6,715	16,200	5,140	0,690	0,331	1,625	3,600	500.090
90	1,807	6,2E-03	38,990	4,580	6,680	17,000	5,060	0,690	0,414	1,630	3,500	453.420
91	1,790	4,3E-03	38,530	4,530	6,635	16,500	5,190	0,630	0,356	1,750	3,425	339.680
92	1,708	4,7E-03	41,850	4,680	6,635	17,000	5,180	0,620	0,331	1,870	3,125	372.499
93	1,749	3,5E-03	38,720	4,450	6,555	17,200	5,110	0,690	0,331	1,560	3,525	336.950
94	1,700	5,5E-03	40,370	4,590	6,365	20,000	5,040	0,630	0,340	1,550	3,225	403.686
95	1,766	5,5E-03	40,800	5,910	4,995	19,500	5,040	0,720	0,356	1,650	3,350	369.197
96	1,708	4,1E-03	39,150	5,720	4,835	17,800	5,110	0,670	0,344	1,750	3,650	361.872
97	1,704	4,1E-03	41,820	4,590	6,770	17,500	5,110	0,650	0,281	1,650	3,500	268.121
98	1,741	8,3E-03	35,740	5,265	5,605	25,800	4,960	0,670	0,423	1,700	3,400	302.634
99	1,778	8,3E-03	39,520	4,570	6,570	16,800	5,070	0,700	0,423	1,630	3,450	297.146
100	1,856	2,8E-03	40,350	4,560	6,720	17,000	5,070	0,650	0,330	1,500	3,800	547.223
101	1,660	2,1E-03	35,850	5,320	6,090	18,540	4,260	0,710	0,303	1,924	3,300	368.639
102	1,540	2,8E-03	34,580	5,045	6,100	18,670	4,820	0,540	0,310	1,667	3,100	594.874
103	1,671	2,1E-03	40,390	4,720	6,620	17,950	5,000	0,690	0,232	1,308	3,380	203.268
104	1,734	4,1E-03	42,990	4,705	6,570	17,430	4,840	1,180	0,303	1,327	3,280	343.511
105	1,587	2,1E-03	38,600	4,705	6,660	16,480	4,840	0,560	0,462	1,524	3,500	426.770
106	1,844	1,4E-03	35,070	5,130	4,760	17,510	4,880	0,890	0,333	1,519	3,270	416.523
107	1,967	2,8E-03	34,850	5,455	5,160	17,510	4,980	0,740	0,326	1,717	3,400	373.169
108	1,781	2,8E-03	42,380	5,070	5,630	22,660	4,560	0,630	0,378	1,431	2,700	241.920
109	1,854	4,1E-03	37,540	5,970	6,680	17,510	4,910	0,540	0,329	1,608	3,200	262.286
110	1,755	1,4E-03	36,400	5,290	6,580	18,280	5,010	0,720	0,346	1,569	3,600	252.810
111	1,744	1,4E-03	36,540	5,365	6,610	18,030	5,000	0,690	0,381	1,662	3,200	294.164
112	1,802	4,7E-03	38,830	5,000	4,900	21,370	4,920	0,630	0,410	1,830	3,300	390.685
113	1,666	1,8E-03	38,560	4,865	6,710	17,300	4,910	0,920	0,355	1,815	3,030	270.210
114	1,585	1,4E-03	37,690	5,130	6,240	21,630	4,750	0,500	0,371	1,736	3,300	374.883
115	1,655	2,1E-03	39,480	4,850	6,730	16,480	4,970	0,670	0,342	1,751	3,400	490.506
116	1,596	1,4E-03	36,960	4,950	6,300	21,370	5,050	0,540	0,381	1,805	3,380	420.986
117	1,739	5,5E-03	39,210	4,590	6,510	16,480	4,680	0,650	0,333	1,722	3,100	359.889
118	1,786	2,5E-03	33,210	5,275	6,640	16,480	5,000	0,640	0,316	1,776	3,430	278.408
119	1,752	2,8E-03	34,350	5,255	6,590	17,250	5,010	0,640	0,268	1,869	3,130	239.917
120	1,687	2,1E-03	36,400	5,405	6,290	17,830	5,140	0,690	0,336	1,726	3,580	283.597
121	1,645	1,4E-03	32,180	5,210	6,570	16,480	4,540	0,790	0,287	1,756	3,730	302.587

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG	CS
122	1,671	2,0E-03	33,250	4,825	6,580	15,430	4,440	0,630	0,238	1,628	3,700	276.248
123	1,718	2,1E-03	33,780	4,830	6,790	14,420	4,310	0,630	0,255	1,598	3,480	269.404
124	1,723	2,1E-03	35,050	5,070	6,610	17,630	4,820	0,690	0,255	1,682	3,600	278.950
125	1,697	2,3E-03	39,750	5,135	6,540	17,770	4,980	0,780	0,290	1,667	3,900	258.561
126	1,747	2,1E-03	36,100	4,985	6,350	17,500	5,250	0,740	0,320	1,726	3,600	285.271
127	1,632	2,3E-03	36,120	5,265	5,960	18,540	5,200	0,670	0,323	1,628	3,430	253.657
128	1,632	4,1E-03	37,500	5,735	5,400	19,480	5,030	0,710	0,369	1,677	3,700	335.571
129	1,784	2,5E-03	38,380	4,790	6,440	18,030	4,910	0,780	0,242	1,825	3,000	393.624
130	1,739	1,8E-03	37,690	5,080	6,490	19,310	5,050	0,630	0,271	1,529	3,200	249.706
131	1,684	3,1E-03	39,400	5,170	6,390	19,570	5,060	0,780	0,268	1,776	3,000	148.100
132	1,674	6,2E-03	32,870	5,685	6,280	20,090	4,520	0,640	0,274	1,628	3,950	417.645
133	1,831	1,4E-03	35,950	5,135	6,780	17,510	5,150	0,650	0,342	1,815	3,400	518.009
134	1,674	2,4E-03	36,880	5,215	6,580	21,630	5,100	0,590	0,320	1,687	3,400	433.148
135	1,686	2,8E-03	34,200	5,165	6,700	16,990	5,110	0,720	0,287	1,712	3,680	431.332
136	1,697	2,4E-03	37,410	5,180	6,650	16,220	4,800	0,590	0,287	1,761	3,680	464.141
137	1,682	2,3E-03	35,300	5,090	6,480	17,510	4,940	0,600	0,320	1,722	3,400	389.557
138	1,666	3,1E-03	35,490	5,200	6,470	17,510	4,890	0,770	0,336	1,786	3,500	680.290
139	1,697	2,9E-03	36,000	5,085	6,510	17,250	5,190	0,670	0,358	1,682	3,400	312.437
140	1,799	4,1E-03	32,710	5,055	6,700	22,660	4,720	0,610	0,358	1,795	3,700	434.835
141	1,713	3,7E-03	35,310	5,470	5,960	20,600	4,800	0,600	0,368	1,638	3,400	396.500
142	1,713	4,7E-03	36,840	5,125	6,530	17,510	4,860	0,680	0,336	1,727	3,600	466.091
143	1,839	3,3E-03	34,280	5,065	6,540	17,250	4,970	0,650	0,375	1,736	4,000	276.136
144	1,658	2,9E-03	33,700	5,160	6,660	17,250	5,020	0,640	0,287	1,766	3,800	395.496
145	1,666	2,3E-03	35,430	5,950	6,710	17,510	5,030	0,620	0,277	1,756	3,600	412.353
146	1,666	2,5E-03	37,070	5,240	6,520	17,250	4,980	0,610	0,300	1,628	3,450	211.639
147	1,744	3,3E-03	37,530	4,670	6,560	18,540	4,940	0,570	0,281	1,391	3,200	385.945
148	1,540	1,8E-03	33,750	5,770	5,530	28,840	4,740	0,740	0,368	1,746	3,500	592.161
149	1,547	2,5E-03	34,260	5,300	6,530	20,600	4,980	0,740	0,238	1,667	3,500	267.093
150	1,721	2,5E-03	36,180	5,310	6,560	18,540	4,740	0,720	0,261	1,628	3,500	269.374
151	1,674	2,9E-03	35,380	5,385	6,450	22,660	4,890	0,700	0,245	1,662	3,400	234.577
152	1,611	3,3E-03	35,780	5,010	6,730	18,540	4,810	0,640	0,209	1,722	3,550	299.484
153	1,705	2,6E-03	34,510	5,310	6,020	20,600	4,990	0,670	0,342	1,690	3,500	555.519
154	1,854	1,8E-03	36,310	5,720	6,020	23,690	4,860	0,620	0,417	1,633	3,400	447.209
155	1,768	3,7E-03	38,940	5,190	6,680	17,510	4,940	0,670	0,371	1,633	3,300	344.919
156	1,792	2,9E-03	35,160	5,445	6,560	20,090	4,850	0,060	0,365	1,736	3,400	315.965
157	1,839	3,3E-03	34,620	5,225	6,840	16,480	4,880	0,710	0,307	1,756	3,500	358.157
158	1,789	3,2E-03	34,240	5,250	6,870	17,510	4,890	0,670	0,371	1,815	3,600	224.569
159	1,776	3,7E-03	37,070	5,795	6,100	23,690	4,590	0,650	0,342	1,677	3,400	393.621
160	1,799	1,8E-03	36,500	5,330	6,870	17,510	4,570	0,630	0,384	1,618	3,650	513.836
161	1,894	3,8E-03	38,560	5,060	6,860	17,770	4,900	0,700	0,320	1,766	3,500	390.849
162	1,697	2,6E-03	34,550	4,945	6,710	15,450	4,630	0,650	0,360	1,485	3,400	264.858
163	1,749	3,7E-03	39,550	5,625	6,090	19,570	4,800	0,700	0,303	1,741	3,800	448.381
164	1,898	2,9E-03	39,440	5,050	6,670	18,800	4,870	0,640	0,290	0,290	3,700	221.456

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG	CS
165	1,843	2,5E-03	37,380	5,480	6,420	18,330	4,940	0,750	0,342	1,677	3,700	497.723
166	1,819	3,0E-03	34,240	5,120	6,550	18,540	4,800	0,710	0,232	1,692	3,250	412.729
167	1,843	2,9E-03	33,970	4,940	6,700	16,480	4,540	0,730	0,255	1,736	3,600	287.263
168	1,882	2,5E-03	39,710	4,980	6,660	18,540	4,310	0,700	0,326	1,751	3,600	324.364
169	1,757	2,1E-03	32,560	5,415	6,640	17,510	4,760	0,630	0,342	1,707	3,500	593.510
170	1,767	2,3E-03	37,680	5,450	6,650	19,510	4,700	0,680	0,290	1,726	3,800	322.925
171	1,760	2,3E-03	31,950	5,160	6,520	18,540	4,530	0,650	0,284	1,702	3,900	279.511
172	1,707	2,5E-03	33,710	5,215	6,010	25,750	4,550	0,750	0,355	1,795	3,600	526.976
173	2,010	3,0E-03	38,370	5,140	6,580	18,800	4,560	0,790	0,407	1,712	4,200	331.178
174	1,843	2,5E-03	38,290	5,410	6,290	25,750	4,340	0,980	0,401	1,766	3,800	551.266
175	1,822	3,2E-03	40,320	5,205	6,540	20,090	4,280	0,630	0,368	1,825	3,800	378.682
176	1,896	5,5E-03	40,930	5,550	6,720	17,510	4,980	0,690	0,410	1,726	3,600	327.996
177	1,833	2,5E-03	44,220	5,330	6,530	17,630	4,790	0,720	0,365	1,776	3,700	312.291
178	1,741	3,3E-03	34,430	5,551	6,420	19,570	5,070	0,640	0,352	1,791	4,000	291.017
179	1,841	3,8E-03	34,550	5,535	6,500	20,600	5,070	0,690	0,307	1,850	3,600	397.432
180	1,917	3,7E-03	39,550	6,210	6,060	17,630	4,640	0,600	0,355	1,776	3,500	400.730
181	1,792	2,6E-03	38,260	5,450	6,510	18,330	4,580	0,640	0,320	1,800	3,600	183.727
182	1,605	3,1E-03	37,450	4,540	6,340	14,420	3,650	0,650	0,238	1,391	3,000	179.481
183	1,833	3,3E-03	42,650	5,350	6,670	18,540	4,930	0,730	0,313	1,840	3,700	183.825
184	1,833	2,6E-03	43,840	5,385	6,600	16,480	4,690	0,680	0,303	1,756	3,600	184.561
185	1,778	3,6E-03	42,730	5,415	6,560	18,030	4,760	0,840	0,349	1,776	3,800	357.572
186	1,766	3,4E-03	34,510	5,540	6,540	17,830	4,500	0,740	0,213	1,759	4,300	283.275
187	1,747	3,1E-03	40,090	5,625	6,320	19,570	4,850	0,740	0,238	1,534	3,500	291.445
188	1,857	2,5E-03	41,960	5,420	6,670	17,510	4,790	0,540	0,375	1,702	4,300	645.882
189	1,773	2,9E-03	35,920	5,755	6,000	23,690	4,890	0,690	0,320	1,574	3,600	308.133
190	1,810	3,0E-03	44,140	5,390	6,230	19,570	5,000	0,690	0,320	1,781	3,700	184.604
191	1,813	4,1E-03	43,570	5,260	6,630	18,540	4,650	0,890	0,384	1,697	3,630	152.696
192	1,789	4,5E-03	44,060	5,780	6,080	23,690	4,720	0,790	0,320	1,697	3,600	346.713

V : Viscosidad

AC : Acidez Titulable

K : Potasio

D : Dilatometría

L : Lactosa

MG :Materia Grasa

TS : Tensión Superficial

PS : Proteína del Suero

CS : Células Somáticas

C : Conductividad Eléctrica

S : Sodio

Anexo 2.- Valores asignados (VA) a las 192 muestras de leche según contenido celular (CS)

Nº	CS	VA						
1	354.056	0,9	41	128.692	0,9	83	279.136	0,1
2	456.941	0,9	42	301.458	0,9	84	421.255	0,9
3	503.711	0,9	43	331.303	0,9	85	424.876	0,9
4	438.421	0,9	44	360.724	0,9	86	299.911	0,1
5	583.641	0,9	45	363.401	0,9	87	269.803	0,1
6	558.168	0,9	46	248.801	0,1	88	224.682	0,1
7	388.376	0,9	47	415.410	0,9	89	500.090	0,9
8	263.729	0,1	48	263.516	0,1	90	453.420	0,9
9	403.681	0,9	49	375.608	0,9	91	339.680	0,9
10	234.855	0,1	50	550.606	0,9	92	372.499	0,9
11	383.450	0,9	51	313.530	0,9	93	336.950	0,9
12	307.030	0,9	52	704.119	0,9	94	403.686	0,9
13	428.168	0,9	53	547.096	0,9	95	369.197	0,9
14	397.857	0,9	54	398.935	0,9	96	361.872	0,9
15	315.739	0,9	55	358.277	0,9	97	268.121	0,1
16	406.232	0,9	56	436.655	0,9	98	302.634	0,9
17	308.489	0,9	57	463.314	0,9	99	297.146	0,1
18	341.781	0,9	58	313.729	0,9	100	547.223	0,9
19	319.486	0,9	59	389.613	0,9	101	368.639	0,9
20	338.398	0,9	60	700.597	0,9	102	594.874	0,9
21	474.410	0,9	61	331.658	0,9	103	203.268	0,1
22	344.387	0,9	62	520.380	0,9	104	343.511	0,9
23	361.085	0,9	63	272.183	0,1	105	426.770	0,9
24	328.053	0,9	64	290.054	0,1	106	416.523	0,9
25	329.180	0,1	65	749.260	0,9	107	373.169	0,9
26	279.165	0,1	66	400.955	0,9	108	241.920	0,1
27	430.811	0,9	67	374.791	0,9	109	262.286	0,1
28	345.673	0,9	68	402.959	0,9	110	252.810	0,1
29	500.671	0,9	69	323.507	0,9	111	294.164	0,1
30	309.831	0,9	70	351.145	0,9	112	390.685	0,9
31	477.636	0,9	71	373.296	0,9	113	270.210	0,1
32	367.154	0,9	72	450.079	0,9	114	374.883	0,9
33	431.918	0,9	73	484.640	0,9	115	490.506	0,9
34	222.520	0,1	74	200.920	0,1	116	420.986	0,9
35	232.420	0,1	75	395.120	0,9	117	359.889	0,9
36	299.033	0,1	76	472.256	0,9	118	278.408	0,1
37	232.956	0,1	77	237.511	0,1	119	239.917	0,1
38	341.557	0,9	78	294.254	0,1	120	283.597	0,1
39	429.611	0,9	79	360.529	0,9	121	302.587	0,9
40	346.382	0,9	80	508.234	0,9	122	276.248	0,1
			81	194.233	0,1	123	269.404	0,1
			82	366.179	0,9	124	278.950	0,1

N°	CS	VA
125	258.561	0,1
126	285.271	0,1
127	253.657	0,1
128	335.571	0,9
129	393.624	0,9
130	249.706	0,1
131	148.100	0,1
132	417.645	0,9
133	518.009	0,9
134	433.148	0,9
135	431.332	0,9
136	464.141	0,9
137	389.557	0,9
138	680.290	0,9
139	312.437	0,9
140	434.835	0,9
141	396.500	0,9
142	466.091	0,9
143	276.136	0,1
144	395.496	0,9
145	412.353	0,9
146	211.639	0,1
147	385.945	0,9
148	592.161	0,9
149	267.093	0,1
150	269.374	0,1
151	234.577	0,1
152	299.484	0,1
153	555.519	0,9
154	447.209	0,9
155	344.919	0,9
156	315.965	0,9
157	358.157	0,9
158	224.569	0,1

159	393.621	0,9
160	513.836	0,9
161	390.849	0,9
162	264.858	0,1
163	448.381	0,9
164	221.456	0,1
165	497.723	0,9
166	412.729	0,9
167	287.263	0,1
168	324.364	0,9
169	593.510	0,9
170	322.925	0,9
171	279.511	0,1
172	526.976	0,9
173	331.178	0,9
174	551.266	0,9
175	378.682	0,9
176	327.996	0,9
177	312.291	0,9
178	291.017	0,1
179	397.432	0,9
180	400.730	0,9
181	183.727	0,1
182	179.481	0,1
183	183.825	0,1
184	184.561	0,1
185	357.572	0,9
186	283.275	0,1
187	291.445	0,1
188	645.882	0,9
189	308.133	0,9
190	184.604	0,1
191	152.696	0,1
192	346.713	0,9

Anexo 3.- Datos normalizados de las propiedades físico-químicas y de composición de las 170 muestras de leche cruda para el entrenamiento de la RNA.

Nº	V	D	TS	C	pH	AT	L	PS	S	P	MG
1	0,669	0,465	0,821	0,766	0,942	0,690	0,878	0,583	0,623	0,497	0,876
2	0,667	0,500	0,815	0,717	0,956	0,690	0,919	0,533	0,640	0,543	0,853
3	0,625	0,577	0,784	0,748	0,956	0,657	0,885	0,683	0,623	0,512	0,760
4	0,615	0,439	0,822	0,773	0,914	0,723	0,885	0,542	0,614	0,497	0,806
5	0,684	0,303	0,793	0,730	0,954	0,699	0,919	0,583	0,658	0,505	0,760
6	0,599	0,377	0,792	0,739	0,914	0,690	0,885	0,592	0,623	0,491	0,691
7	0,627	0,361	0,764	0,750	0,957	0,699	0,905	0,525	0,623	0,497	0,806
8	0,642	0,393	0,803	0,749	0,953	0,625	0,850	0,575	0,668	0,454	0,841
9	0,691	0,708	0,782	0,741	0,956	0,592	0,854	0,617	0,640	0,505	0,893
10	0,627	0,505	0,798	0,753	0,961	0,584	0,878	0,567	0,640	0,493	0,743
11	0,665	0,217	0,799	0,745	0,961	0,567	0,843	0,567	0,567	0,435	0,818
12	0,689	0,435	0,794	0,768	0,943	0,625	0,861	0,558	0,579	0,474	0,835
13	0,671	0,425	0,800	0,735	0,966	0,690	0,881	0,500	0,439	0,512	0,841
14	0,699	0,478	0,807	0,744	0,959	0,559	0,871	0,583	0,561	0,454	0,864
15	0,708	0,542	0,872	0,738	0,949	0,592	0,809	0,550	0,579	0,494	0,876
16	0,996	0,367	0,811	0,748	0,955	0,796	0,850	0,583	0,660	0,994	0,818
17	0,622	0,531	0,750	0,714	0,966	0,675	0,864	0,583	0,965	0,955	0,853
18	0,601	0,333	0,782	0,753	0,962	0,621	0,864	0,583	0,493	0,494	0,806
19	0,649	0,349	0,779	0,790	0,964	0,625	0,871	0,483	0,579	0,500	0,945
20	0,623	0,350	0,779	0,772	0,963	0,625	0,884	0,317	0,493	0,484	0,899
21	0,633	0,383	0,909	0,730	0,960	0,625	0,884	0,550	0,579	0,505	0,907
22	0,601	0,491	0,840	0,729	0,961	0,625	0,891	0,550	0,491	0,474	0,795
23	0,629	0,384	0,881	0,738	0,963	0,592	0,802	0,592	0,505	0,474	0,783
24	0,661	0,830	0,902	0,761	0,959	0,625	0,834	0,742	0,482	0,466	0,829
25	0,674	0,465	0,834	0,734	0,962	0,625	0,854	0,558	0,625	0,481	0,853
26	0,644	0,370	0,969	0,739	0,967	0,592	0,789	0,550	0,579	0,443	0,806
27	0,626	0,482	0,844	0,779	0,939	0,828	0,814	0,608	0,439	0,443	0,812
28	0,574	0,331	0,848	0,772	0,924	0,690	0,802	0,542	0,614	0,416	0,853
29	0,598	0,354	0,894	0,767	0,956	0,723	0,796	0,550	0,596	0,427	0,835
30	0,572	0,372	0,889	0,746	0,956	0,598	0,829	0,533	0,561	0,446	0,795
31	0,598	0,414	0,848	0,722	0,954	0,575	0,829	0,550	0,596	0,481	0,850
32	0,589	0,439	0,872	0,726	0,947	0,612	0,829	0,575	0,614	0,511	0,876
33	0,600	0,310	0,949	0,730	0,948	0,756	0,791	0,542	0,658	0,497	0,853
34	0,606	0,284	0,913	0,819	0,874	0,618	0,718	0,558	0,561	0,509	0,887
35	0,632	0,345	0,912	0,760	0,946	0,625	0,861	0,542	0,724	0,553	0,783
36	0,638	0,377	0,833	0,709	0,961	0,625	0,868	0,533	0,811	0,559	0,806
37	0,621	0,354	0,899	0,746	0,978	0,625	0,986	0,592	0,724	0,559	0,806
38	0,628	0,307	0,887	0,738	0,972	0,625	0,995	0,625	0,658	0,543	0,876
39	0,628	0,444	0,851	0,730	0,967	0,625	0,954	0,600	0,724	0,559	0,922
40	0,702	0,502	0,924	0,700	0,970	0,575	0,986	0,592	0,789	0,481	0,997
41	0,650	0,363	0,896	0,791	0,969	0,592	0,945	0,575	0,772	0,453	0,806

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG
42	0,632	0,413	0,859	0,822	0,955	0,592	0,904	0,517	0,579	0,489	0,853
43	0,625	0,457	0,892	0,746	0,967	0,723	0,896	0,525	0,754	0,506	0,806
44	0,659	0,494	0,884	0,730	0,963	0,828	0,916	0,517	0,754	0,506	0,835
45	0,603	0,395	0,869	0,766	0,951	0,690	0,907	0,525	0,702	0,481	0,806
46	0,661	0,464	0,845	0,734	0,969	0,618	0,938	0,500	0,632	0,543	0,847
47	0,636	0,469	0,924	0,734	0,976	0,585	0,920	0,600	0,579	0,466	0,922
48	0,648	0,502	0,909	0,758	0,966	0,625	0,916	0,683	0,579	0,494	0,829
49	0,590	0,365	0,903	0,827	0,989	0,756	0,909	0,625	0,667	0,503	0,783
50	0,619	0,384	0,874	0,732	0,943	0,660	0,911	0,608	0,596	0,497	0,795
51	0,638	0,365	0,972	0,758	0,957	0,629	0,907	0,567	0,579	0,497	0,720
52	0,634	0,360	0,946	0,783	0,959	0,604	0,902	0,567	0,658	0,497	0,812
53	0,621	0,280	0,937	0,756	0,970	0,603	0,913	0,583	0,505	0,501	0,812
54	0,623	0,495	0,964	0,757	0,959	0,611	0,909	0,617	0,596	0,543	0,829
55	0,615	0,360	0,984	0,756	0,953	0,604	0,921	0,583	0,579	0,512	0,801
56	0,642	0,895	1,000	0,745	0,963	0,594	0,909	0,608	0,532	0,505	0,812
57	0,615	0,745	0,959	0,742	0,946	0,611	0,889	0,558	0,625	0,551	0,732
58	0,625	0,510	0,951	0,747	0,959	0,646	0,913	0,575	0,579	0,481	0,829
59	0,625	0,410	0,944	0,670	0,959	0,629	0,905	0,575	0,579	0,493	0,812
60	0,611	0,725	0,918	0,798	0,898	0,681	0,868	0,533	0,596	0,586	0,737
61	0,621	0,610	0,978	0,777	0,953	0,646	0,921	0,517	0,596	0,505	0,806
62	0,636	0,395	0,893	0,732	0,964	0,727	0,884	0,558	0,789	0,493	0,876
63	0,638	0,415	0,918	0,746	0,962	0,616	0,882	0,583	0,596	0,493	0,783
64	0,619	0,410	0,926	0,753	0,951	0,595	0,902	0,583	0,596	0,543	0,783
65	0,659	0,690	0,899	0,788	0,884	0,699	0,855	0,558	0,611	0,501	0,899
66	0,644	0,410	0,951	0,705	0,949	0,709	0,913	0,575	0,693	0,528	0,806
67	0,636	0,500	0,957	0,765	0,956	0,692	0,952	0,575	0,614	0,373	0,853
68	0,615	0,344	0,878	0,766	0,953	0,675	0,909	0,517	0,610	0,531	0,760
69	0,619	0,248	0,963	0,754	0,966	0,640	0,938	0,592	0,631	0,520	0,835
70	0,642	0,295	0,926	0,758	0,964	0,664	0,930	0,583	0,589	0,509	0,806
71	0,650	0,138	0,933	0,762	0,959	0,692	0,921	0,592	0,623	0,516	0,772
72	0,661	0,413	0,928	0,767	0,961	0,623	0,925	0,575	0,526	0,507	0,760
73	0,625	0,413	0,932	0,788	0,923	0,709	0,895	0,592	0,650	0,501	0,829
74	0,625	0,413	0,901	0,733	0,961	0,606	0,927	0,608	0,396	0,485	0,772
75	0,609	0,496	0,978	0,756	0,950	0,657	0,898	0,475	0,575	0,497	0,760
76	0,650	0,206	0,909	0,791	0,871	0,865	0,905	0,592	0,640	0,543	0,737
77	0,655	0,413	0,893	0,745	0,963	0,709	0,938	0,567	0,537	0,489	0,772
78	0,636	0,620	0,854	0,753	0,965	0,727	0,923	0,600	0,596	0,505	0,760
79	0,664	0,207	0,922	0,766	0,894	0,692	0,886	0,592	0,644	0,497	0,755
80	0,725	0,383	0,856	0,726	0,959	0,588	0,864	0,592	0,614	0,505	0,858
81	0,654	0,319	0,885	0,735	0,962	0,595	0,918	0,608	0,602	0,521	0,743
82	0,644	0,413	0,864	0,769	0,901	0,640	0,914	0,525	0,625	0,505	0,766
83	0,632	0,551	0,905	0,751	0,923	0,623	0,888	0,558	0,625	0,536	0,755
84	0,647	0,276	0,844	0,798	0,826	0,813	0,902	0,467	0,537	0,505	0,749

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG
85	0,659	0,413	0,865	0,730	0,961	0,554	0,914	0,458	0,614	0,528	0,806
86	0,675	0,496	0,877	0,742	0,953	0,623	0,893	0,575	0,625	0,512	0,778
87	0,656	0,579	0,899	0,721	0,949	0,588	0,916	0,558	0,581	0,505	0,760
88	0,638	0,496	0,856	0,709	0,966	0,554	0,904	0,542	0,644	0,543	0,806
89	0,641	0,413	0,834	0,726	0,959	0,561	0,918	0,575	0,581	0,505	0,829
90	0,650	0,620	0,851	0,735	0,954	0,588	0,904	0,575	0,726	0,506	0,806
91	0,644	0,434	0,841	0,727	0,948	0,571	0,927	0,525	0,625	0,543	0,789
92	0,614	0,465	0,914	0,751	0,948	0,588	0,925	0,517	0,581	0,581	0,720
93	0,629	0,354	0,845	0,714	0,936	0,595	0,913	0,575	0,581	0,484	0,812
94	0,611	0,551	0,881	0,737	0,909	0,692	0,900	0,525	0,596	0,481	0,743
95	0,635	0,551	0,891	0,949	0,714	0,675	0,900	0,600	0,625	0,512	0,772
96	0,614	0,413	0,855	0,918	0,691	0,616	0,913	0,558	0,604	0,543	0,841
97	0,613	0,413	0,913	0,737	0,967	0,606	0,913	0,542	0,493	0,512	0,806
98	0,626	0,826	0,780	0,845	0,801	0,893	0,886	0,558	0,742	0,528	0,783
99	0,639	0,826	0,863	0,734	0,939	0,581	0,905	0,583	0,742	0,506	0,795
100	0,668	0,275	0,881	0,732	0,960	0,588	0,905	0,542	0,579	0,466	0,876
101	0,597	0,210	0,783	0,854	0,870	0,642	0,761	0,592	0,532	0,598	0,760
102	0,554	0,275	0,755	0,810	0,871	0,646	0,861	0,533	0,544	0,518	0,714
103	0,601	0,207	0,882	0,758	0,946	0,621	0,893	0,575	0,407	0,406	0,779
104	0,624	0,413	0,939	0,755	0,939	0,603	0,864	0,983	0,532	0,412	0,756
105	0,571	0,207	0,843	0,755	0,951	0,570	0,864	0,467	0,811	0,473	0,806
106	0,663	0,138	0,766	0,823	0,680	0,606	0,871	0,742	0,584	0,472	0,753
107	0,707	0,276	0,761	0,876	0,737	0,606	0,889	0,617	0,572	0,533	0,783
108	0,641	0,275	0,925	0,814	0,804	0,784	0,814	0,525	0,663	0,444	0,622
109	0,667	0,413	0,820	0,958	0,954	0,606	0,877	0,450	0,577	0,499	0,737
110	0,631	0,138	0,795	0,849	0,940	0,633	0,895	0,600	0,607	0,487	0,829
111	0,627	0,138	0,798	0,861	0,944	0,624	0,893	0,575	0,668	0,516	0,737
112	0,648	0,472	0,848	0,803	0,700	0,739	0,879	0,525	0,719	0,568	0,760
113	0,599	0,184	0,842	0,781	0,959	0,599	0,877	0,767	0,623	0,564	0,698
114	0,570	0,138	0,823	0,823	0,891	0,748	0,848	0,417	0,651	0,539	0,760
115	0,595	0,207	0,862	0,778	0,961	0,570	0,888	0,558	0,600	0,544	0,783
116	0,574	0,138	0,807	0,795	0,900	0,739	0,902	0,450	0,668	0,561	0,779
117	0,625	0,551	0,856	0,737	0,930	0,570	0,836	0,542	0,584	0,535	0,714
118	0,642	0,254	0,725	0,847	0,949	0,570	0,893	0,533	0,555	0,551	0,790
119	0,630	0,275	0,750	0,843	0,941	0,597	0,895	0,533	0,469	0,581	0,721
120	0,607	0,207	0,795	0,868	0,899	0,617	0,918	0,575	0,589	0,536	0,825
121	0,592	0,138	0,703	0,836	0,939	0,570	0,811	0,658	0,504	0,545	0,859
122	0,601	0,198	0,726	0,774	0,940	0,534	0,793	0,525	0,418	0,506	0,853
123	0,618	0,207	0,738	0,775	0,970	0,499	0,770	0,525	0,447	0,496	0,802
124	0,620	0,207	0,765	0,814	0,944	0,610	0,861	0,575	0,447	0,522	0,829
125	0,611	0,230	0,868	0,824	0,934	0,615	0,889	0,650	0,509	0,518	0,899
126	0,628	0,207	0,788	0,800	0,907	0,606	0,938	0,617	0,561	0,536	0,829
127	0,587	0,230	0,789	0,845	0,851	0,642	0,929	0,558	0,566	0,506	0,790

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG
128	0,587	0,413	0,819	0,921	0,771	0,674	0,898	0,592	0,647	0,521	0,853
129	0,642	0,248	0,838	0,769	0,920	0,624	0,877	0,650	0,424	0,567	0,691
130	0,625	0,177	0,823	0,815	0,927	0,668	0,902	0,525	0,475	0,475	0,737
131	0,606	0,310	0,860	0,830	0,913	0,677	0,904	0,650	0,469	0,551	0,691
132	0,602	0,620	0,718	0,913	0,897	0,695	0,807	0,533	0,481	0,506	0,910
133	0,659	0,138	0,785	0,824	0,969	0,606	0,920	0,542	0,600	0,564	0,783
134	0,602	0,241	0,805	0,837	0,940	0,748	0,911	0,492	0,561	0,524	0,783
135	0,607	0,275	0,747	0,829	0,957	0,588	0,913	0,600	0,504	0,532	0,848
136	0,611	0,241	0,817	0,831	0,950	0,561	0,857	0,492	0,504	0,547	0,848
137	0,605	0,230	0,771	0,817	0,926	0,606	0,882	0,500	0,561	0,535	0,783
138	0,599	0,310	0,775	0,835	0,924	0,606	0,873	0,642	0,589	0,555	0,806
139	0,611	0,289	0,786	0,816	0,930	0,597	0,927	0,558	0,628	0,522	0,783
140	0,647	0,413	0,714	0,811	0,957	0,784	0,843	0,508	0,628	0,557	0,853
141	0,616	0,367	0,771	0,878	0,851	0,713	0,857	0,500	0,646	0,509	0,783
142	0,616	0,465	0,804	0,823	0,933	0,606	0,868	0,567	0,589	0,536	0,829
143	0,661	0,331	0,748	0,813	0,934	0,597	0,888	0,542	0,658	0,539	0,922
144	0,596	0,289	0,736	0,828	0,951	0,597	0,896	0,533	0,504	0,548	0,876
145	0,599	0,230	0,774	0,955	0,959	0,606	0,898	0,517	0,486	0,545	0,829
146	0,599	0,248	0,809	0,841	0,931	0,597	0,889	0,508	0,526	0,506	0,795
147	0,627	0,331	0,819	0,750	0,937	0,642	0,882	0,475	0,493	0,432	0,737
148	0,554	0,184	0,737	0,926	0,790	0,998	0,846	0,617	0,646	0,542	0,806
149	0,556	0,248	0,748	0,851	0,933	0,713	0,889	0,617	0,418	0,518	0,806
150	0,619	0,248	0,790	0,852	0,937	0,642	0,846	0,600	0,458	0,506	0,806
151	0,602	0,289	0,772	0,864	0,921	0,784	0,873	0,583	0,430	0,516	0,783
152	0,579	0,331	0,781	0,804	0,961	0,642	0,859	0,533	0,367	0,535	0,818
153	0,613	0,263	0,753	0,852	0,860	0,713	0,891	0,558	0,600	0,525	0,806
154	0,667	0,184	0,793	0,918	0,860	0,820	0,868	0,517	0,732	0,507	0,783
155	0,636	0,372	0,850	0,833	0,954	0,606	0,882	0,558	0,651	0,507	0,760
156	0,644	0,289	0,768	0,874	0,937	0,695	0,866	0,050	0,640	0,539	0,783
157	0,661	0,331	0,756	0,839	0,977	0,570	0,871	0,592	0,539	0,545	0,806
158	0,642	0,321	0,748	0,843	0,981	0,606	0,873	0,558	0,651	0,564	0,829
159	0,639	0,367	0,809	0,930	0,871	0,820	0,820	0,542	0,600	0,521	0,783
160	0,647	0,184	0,797	0,856	0,981	0,606	0,816	0,525	0,674	0,502	0,841
161	0,681	0,376	0,842	0,812	0,980	0,615	0,875	0,583	0,561	0,548	0,806
162	0,611	0,263	0,754	0,794	0,959	0,535	0,827	0,542	0,632	0,461	0,783
163	0,629	0,371	0,864	0,903	0,870	0,677	0,857	0,583	0,532	0,541	0,876
164	0,683	0,289	0,861	0,811	0,953	0,651	0,870	0,533	0,509	0,510	0,853
165	0,663	0,245	0,816	0,880	0,917	0,643	0,882	0,625	0,600	0,521	0,853
166	0,654	0,301	0,748	0,822	0,936	0,642	0,857	0,592	0,407	0,525	0,749
167	0,663	0,289	0,742	0,793	0,957	0,570	0,811	0,608	0,447	0,539	0,829
168	0,677	0,248	0,867	0,799	0,951	0,642	0,770	0,583	0,572	0,544	0,829
169	0,632	0,207	0,711	0,869	0,949	0,606	0,850	0,525	0,600	0,530	0,806
170	0,635	0,230	0,823	0,875	0,950	0,675	0,839	0,567	0,509	0,536	0,876

Anexo 4.- Datos normalizados de las propiedades físico-químicas y de la composición de las 22 muestras de leche destinadas a probar el poder de predicción de la RNA.

N°	V	D	TS	C	pH	AT	L	PS	S	P	MG
1	0,633	0,230	0,698	0,828	0,931	0,642	0,809	0,542	0,529	0,529	0,899
2	0,614	0,248	0,736	0,837	0,859	0,891	0,813	0,625	0,623	0,557	0,829
3	0,723	0,301	0,838	0,825	0,940	0,651	0,814	0,658	0,714	0,532	0,968
4	0,663	0,248	0,836	0,868	0,899	0,891	0,775	0,567	0,704	0,548	0,876
5	0,655	0,317	0,880	0,835	0,934	0,695	0,764	0,525	0,646	0,567	0,876
6	0,682	0,551	0,894	0,891	0,960	0,606	0,889	0,575	0,719	0,536	0,829
7	0,659	0,248	0,966	0,856	0,933	0,610	0,855	0,600	0,640	0,552	0,853
8	0,626	0,331	0,752	0,891	0,917	0,677	0,905	0,533	0,618	0,556	0,922
9	0,662	0,380	0,754	0,888	0,929	0,713	0,905	0,575	0,539	0,575	0,829
10	0,690	0,372	0,864	0,997	0,866	0,610	0,829	0,500	0,623	0,552	0,806
11	0,644	0,264	0,835	0,875	0,930	0,634	0,818	0,533	0,561	0,559	0,829
12	0,577	0,306	0,818	0,729	0,906	0,499	0,652	0,542	0,418	0,432	0,691
13	0,659	0,331	0,931	0,859	0,953	0,642	0,880	0,608	0,549	0,571	0,853
14	0,659	0,256	0,957	0,864	0,943	0,570	0,838	0,567	0,532	0,545	0,829
15	0,640	0,355	0,933	0,869	0,937	0,624	0,850	0,700	0,612	0,552	0,876
16	0,635	0,339	0,753	0,889	0,934	0,617	0,804	0,617	0,374	0,490	0,991
17	0,628	0,306	0,875	0,903	0,903	0,677	0,866	0,617	0,418	0,476	0,806
18	0,668	0,248	0,916	0,870	0,953	0,606	0,855	0,450	0,658	0,529	0,991
19	0,638	0,288	0,784	0,924	0,857	0,820	0,873	0,575	0,561	0,489	0,829
20	0,651	0,298	0,964	0,865	0,890	0,677	0,893	0,575	0,561	0,553	0,853
21	0,652	0,413	0,951	0,844	0,947	0,642	0,830	0,742	0,674	0,527	0,836
22	0,644	0,446	0,962	0,928	0,869	0,820	0,843	0,658	0,561	0,527	0,829

V : Viscosidad

AC: Acidez Titulable

K : Potasio

D : Dilatometría

L : Lactosa

MG : Materia Grasa

TS :Tensión Superficial

PS : Proteína del Suero

C :Conductividad Eléctrica

S : Sodio

AGRADECIMIENTOS

Expreso mis más sinceros agradecimientos a todas las personas que de una u otra forma colaboraron en la realización de este trabajo. En especial a:

- * **Dr. Bernardo Fraser L.** profesor patrocinante de la tesis, por sus consejos y colaboración durante su realización.
- * **Sr. Erwin Carrasco R.** jefe del proyecto, por su apoyo y especial colaboración en lo referente al material bibliográfico.
- * **Sr. Martín Solar M.** por su valiosa e incondicional colaboración y predisposición en la parte de asesoría y análisis computacional.
- * **Sergio Miranda** por su incondicional amistad y colaboración durante la preparación y presentación de la tesis.
- * **Mi familia** por su constante apoyo espiritual, invaluable ayuda, inagotable paciencia y comprensión y sobretodo por su infinito amor.
- * **Dios y la Virgen y Santa Teresita de los Andes...**