

Clasificación de los elementos de una muestra de sangre utilizando Redes Neuronales

Lic. Lanzarini Laura¹

A.C. Vargas Camacho María Teresa²

Dr. Badrán Amado F.³

Ing. De Giusti Armando.⁴

Laboratorio de Investigación y Desarrollo en Informática.⁵

Departamento de Informática - Facultad de Ciencias Exactas.

Universidad Nacional de La Plata

Resumen

El análisis de una muestra de sangre es una de las prácticas más comunes solicitadas por los médicos para un diagnóstico y pronóstico adecuados. Mediante su estudio es posible detectar distintas patologías que van desde los más simples procesos fisiológicos o inflamatorios a los más complejos procesos neoplásicos (leucemias) y de allí su importancia.

El presente trabajo es una aplicación de reconocimiento de patrones utilizando redes neuronales, actualmente en desarrollo, que permite clasificar los distintos tipos de células que pueden identificarse y cuantificarse.

Introducción.

El problema médico:

Uno de los procedimientos más importantes en la evaluación de la condición de un paciente, es el examen de los elementos figurados de la sangre. Este incluye el estudio microscópico minucioso de la morfología celular y la cuantificación de cada componente

La mayoría de los cuadros patológicos se acompaña de modificaciones en los resultados de estas pruebas y a menudo la sangre brinda información diagnóstica muy valiosa en la identificación de otras patologías.

Los elementos de una muestra de sangre se clasifican en: eritrocitos, o glóbulos rojos, leucocitos o glóbulos blancos y plaquetas.

El sistema eritroide, encargado del transporte del oxígeno, se define por tres parámetros fundamentales: el volumen de glóbulos rojos sedimentados o hematocrito (Ht), el nivel de hemoglobina (Hb) y la cantidad de glóbulos rojos por unidad de volumen (RG).

¹ Prof. Adjunto dedicación Exclusiva del Dpto. de Informática, Fac. Cs. Exactas, UNLP.

² Auxiliar Docente dedicación Simple del Dpto. de Informática, Fac. Cs. Exactas, UNLP.

³ Prof. Titular dedicación Exclusiva. Fac. de Ciencias Médicas, UNLP.

⁴ Director del LIDI. Investigador Principal CONICET. Prof. Titular dedicación Exclusiva del Dpto. de Informática, Fac Cs. Exactas, UNLP.

⁵ LIDI. Laboratorio de Investigación y Desarrollo en Informática, Dpto. de Informática, Fac. de Cs. Exactas, UNLP. Calle 50 y 115 - 1er piso - 1900 La Plata - Buenos Aires - Argentina.
Tel / Fax: 54 - 21 - 22 7707
E-Mail: lidi @ ada.info.unlp.edu.ar

Por su parte, los leucocitos conforman un grupo heterogéneo de células nucleadas encargadas de proteger al huésped de agentes agresores.

Existen cinco tipos: neutrófilos, eosinófilos, basófilos, linfocitos y monocitos. Poseen un aspecto característico y desempeñan un papel fisiológico específico.

Por último, las plaquetas son fragmentos citoplasmáticos que participan en la coagulación y la hemostasia.

Además de la cuantificación de los glóbulos rojos, el estudio hematológico incluye a la cantidad total de leucocitos por unidad de volumen de sangre circulante. Es una cifra que representa la suma total de las cinco categorías de glóbulos blancos.

En el individuo sano corresponde a la concentración de células normales. En un enfermo podría indicar la presencia de formas inmaduras o alteraciones de la proporción de cada una. Por lo tanto, el total debe acompañarse del recuento diferencial o la denominada fórmula leucocitaria, que expresa la relación entre los valores de cada uno de los leucocitos.

El examen morfológico habitual se realiza observando un extendido de sangre periférica teñido mediante la coloración de Wright, que permite el estudio hematológico más preciso, y clasificando a los leucocitos de acuerdo con su morfología mediante la observación microscópica.

Un aspecto importante para que el estudio sea confiable y lo más exacto posible, consiste en prestar particular atención a la recolección y procesamiento de la muestra en el laboratorio. Como existen muchos factores que pueden afectar los resultados, dicha tarea debe estandarizarse para prevenir variaciones preanalíticas.

El segundo aspecto fundamental de la evaluación hematológica es el examen minucioso de la morfología celular. Es probable que contribuya más al diagnóstico que cualquier otra prueba de laboratorio. Casi todas las patologías que involucran a los elementos formes de la sangre se visualizan como alteraciones citológicas o modificaciones en la proporcionalidad de las células.

La morfología celular permite identificar sin mayores problemas, los siguientes elementos figurados de la sangre:

Fig.1

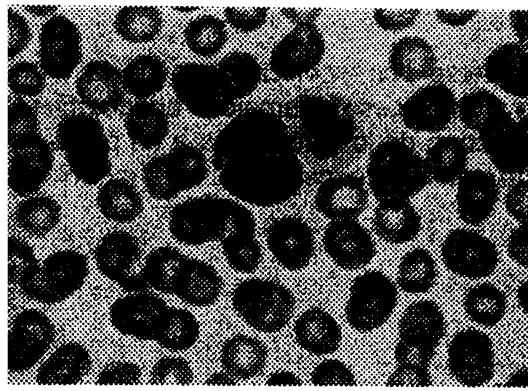


Fig.2

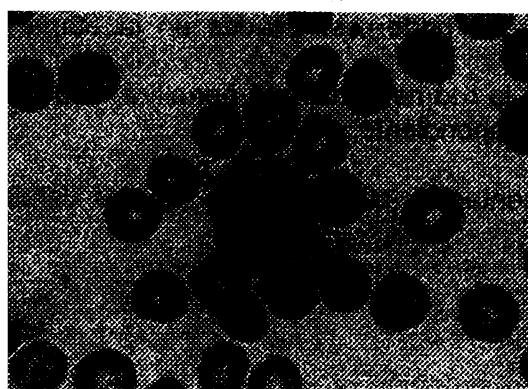


Fig.3

Con el número de cada tipo de leucocitaria, proporción de cada tipo celular
Existen condiciones patológicas que modifican los valores porcentuales de los tipos celulares en el desarrollo de un individuo (Tabla 1)

Edad	Neutrofilos	Linfocito
1 día	61%	31%
1 año	31%	61%
21 años	59%	34%

Objetivo:

Obtener una clasificación automática de los distintos tipos de leucocitos que aparecen en una muestra de sangre utilizando como herramienta para dicha clasificación una red neuronal basada en el Mapa de Kohonen.

Una vez obtenida la clasificación es posible cuantificar el extendido sanguíneo obteniendo así la fórmula leucocitaria del mismo.

Debido a la importancia de los datos numéricos obtenidos de la identificación de los distintos tipos de leucocitos, es deseable tratar de evitar los desvíos producto de la subjetividad del observador, por lo que la aplicación de métodos automatizados, de mayor objetividad, resultarán de suma utilidad.

Aplicaciones de este Trabajo:

Son múltiples las causas que pueden expresarse por modificaciones de la fórmula leucocitaria. Un incremento de los neutrófilos, apunta a un proceso inflamatorio agudo, mientras que un incremento de los linfocitos a un proceso crónico, o de los monocitos a un proceso de tipo tuberculoso, etc. Por su parte, la aparición de células de características morfológicas anormales a procesos de tipo neoplásico.

Análisis del Problema:

La implementación de este trabajo implicó la solución de dos problemas a la vez:

- A) Por un lado, las células deben ser separadas mediante técnicas de procesamiento de imágenes tanto para su clasificación como para poder ser usadas en la etapa de entrenamiento de la red.
- B) Por otro lado, el desarrollo y entrenamiento de la red neuronal que permitirá, dado una imagen de una célula, clasificarla en el tipo correspondiente.

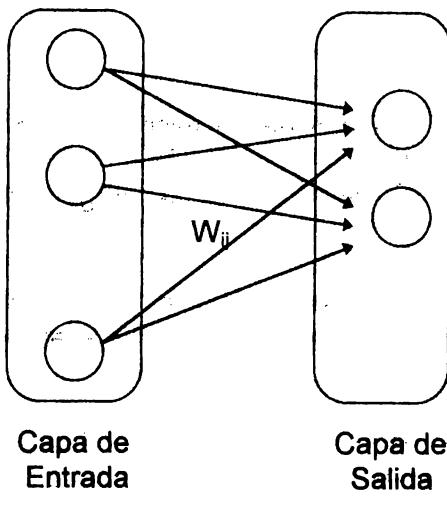
Antes de llegar a los aspectos de implementación, consideremos algunos detalles de la red neuronal utilizada:

Mapa de Kohonen:

En este trabajo se utilizó el Mapa de Kohonen o Mapa Auto-organizativo (SOM)

A) Características de la Red utilizada:

Se consideraron sólo dos capas, la de entrada y la de salida. Cada neurona de entrada está conectada con todas las de salida.



El valor de cada neurona de salida se calcula como: $\text{output} = W_{ij} * X_i$

donde W_{ij} es el peso del arco que va de la neurona de entrada i a la salida j
 X_i es el valor de la entrada i .

B) Clasificación:

La estrategia de clasificación se basa en tomar como salida ganadora la que tenga el mayor valor.

C) Entrenamiento:

Selección de los patrones de entrada:

Los patrones utilizados para entrenar la red deben ser representativos de la población a clasificar.

Se considera patrón a la imagen de una célula. Dicha imagen es ingresada a la red como una secuencia de valores formada por los tonos de grises de la imagen indicados de izquierda a derecha y de arriba a abajo.

Método de Aprendizaje:

Para cada uno de los patrones de entrada se calculan los valores de las neuronas de salida y se actualizan los pesos de las más próximas (vecinas) a la ganadora, que es la que tiene el mayor valor.

Dicha actualización se realiza de la siguiente forma: $W_{\text{new}} = W_{\text{old}} + \alpha * (X - W_{\text{old}})$

Este proceso se repite hasta que la distancia promedio de las entradas con respecto a los pesos es menor que una determinada tolerancia preestablecida.

Tanto el vector de pesos W como el de entrada X están normalizados y α es una ganancia constante entre 0 y 1.

Aspectos de Implementación:

A) Procesamiento de Imágenes:

Para trabajar se utilizaron imágenes tomadas de un microscopio convencional al cual se le colocó una cámara de video intraocular Sony Color CCD. La salida de la cámara fue digitalizada utilizando una placa "Video Blaster" con la cual se generaron imágenes BMP.

Dado que el tamaño del preparado no puede captarse en forma completa con la cámara, el mismo ha sido fragmentado, con lo cual, los datos finales deben agruparse para obtener la información final.

La muestra sanguínea se colorea mediante la coloración de Wright, permitiendo de esta forma separar los leucocitos (glóbulos blancos) de los eritrocitos (glóbulos rojos) ya que los primeros son los únicos que se tiñen de un color rojizo o violeta.

De esto surge una primera segmentación que por color permite separar los eritrocitos (más del 60% de la población celular) del resto. Una vez separados leucocitos y eritrocitos, el color ya no es necesario, por lo tanto, se reduce la imagen a tonos de grises (de esta forma ingresará luego a la red neuronal)

Trabajamos entonces, a partir de ahora, sobre una imagen que sólo contiene leucocitos.

Como se puede apreciar en las imágenes de las págs. 2 y 3, para reconocer de qué tipo de leucocito se trata, es importante identificar el citoplasma que lo rodea, por lo tanto, aplicamos lo siguiente:

Realce de la imagen:

- I. *Ecualización del histograma*: de esta forma, se logra diferenciar mejor los tonos de grises de la imagen. Recordemos que la ecualización distribuye el histograma entre 0 y 255, es decir que si se trata de un imagen clara, se distinguirán mejor los cambios de niveles de gris y si se trata de una imagen con buen contraste, no tendrá efecto .
- II. *Realce logarítmico*: Para separar aún más los tonos de grises intermedios entre, lo que claramente pertenece a la célula y el fondo, se aplicó una función logarítmica. Esta operación marca una distancia mayor entre los valores más oscuros (pertenecientes a las células) y el fondo, que rápidamente se lleva a 255.

Segmentación:

- I. *Thresholding*: Luego de un análisis estadístico de la imagen resultante del punto anterior, se calculó un valor de corte o umbral para llevar la salida a sólo dos tonos de gris, 0 y 255
- II. *Identificación de los bordes*: El borde de cada región se obtuvo restando a la imagen original una erosión y luego se etiquetaron los bordes de cada célula utilizando conectividad 4. Con los bordes identificados es posible extraer por separado las distintas células.

B) Mapa de Kohonen:

Con las imágenes de las células se construyó un archivo de patrones que sirvió para entrenar la red.

El tamaño de cada patrón fue elegido en función de la dimensión del tipo de célula más grande. Las más chicas fueron completadas con el color del fondo a fin de tener un tamaño homogéneo.

De esta forma, todos los registros del archivo tienen el mismo tamaño y su contenido son los tonos de grises de los píxeles de la imagen alineados por fila. El tamaño de cada patrón es de 70x70 (4900 pixels).

Las células utilizadas en el entrenamiento fueron seleccionadas por su variedad y tipo. Se utilizaron tanto leucocitos como eritrocitos y se incluyeron en esta etapa tantas células de cada tipo como indican las distribuciones estadísticas correspondientes a extendidos sanguíneos normales.

La red utilizada fue de 4900 neuronas de entradas, una para cada pixel de la imagen y 150 neuronas de salida, para clasificar en 6 tipos de células distintas.

El archivo de patrones de entrada fue ingresado a la red hasta que la distancia promedio entre los patrones de entrada y los pesos de la red fue menor que 0.05, lo que se logró en aproximadamente 80 a 120 ciclos. Esto depende del área de vecinos actualizada para cada patrón y de la cantidad de neuronas de salida.

En la selección de la neurona de salida ganadora se introdujo además del criterio de la que obtenga el mayor valor de salida, el uso de un threshold de manera que una misma neurona no pueda ser seleccionada dos veces consecutivas, dando así lugar a otras de actualizar sus pesos.

Con respecto a la cantidad de vecinos utilizada en cada actualización el número fue 2. Esto se debe a que los patrones de entradas son muy distintos con lo cual, tomar un número mayor hace que la red considere como neurona de salida ganadora siempre a la misma.

Una vez entrenada la red, se obtuvieron los pesos adecuados para la clasificación. Esta etapa está en implementación ya que, si bien la red puede seguir aprendiendo, existen situaciones límites donde las distintas células aun se confunden

Resultados obtenidos:

El presente trabajo representa una primera clasificación de los distintos tipos celulares presentes en un frotis sanguíneo, aún en etapa de implementación.

Si bien la topología de red neuronal empleada es sencilla, este artículo muestra un ejemplo concreto de implementación de clasificación de patrones representados por imágenes, mediante una red neuronal basada en el Mapa de Kohonen, que utiliza una estructura de datos de aproximadamente 4 Mb, en RAM, para representar los pesos.

El trabajo realizado hasta el momento nos permite distinguir, mediante el cálculo automático de la fórmula leucocitaria situaciones normales y anormales. Esto es de gran

utilidad en patologías de tipo inflamatorias tales como leucocitosis, linfocitosis o monocitosis donde la variación de los elementos dentro de la muestra se da en cantidad y no en forma ni tamaño.

Sin embargo, existen otras patologías de tipo neoplásicas donde estas últimas variaciones (forma y tamaño) si ocurren. Este es el caso de las leucemias ya sean aguda, crónica o linfocítica o en problemas medulares. En estos casos, habría que aplicar técnicas específicas que están fuera de los objetivos de este trabajo.

Trabajos Futuros:

En la actualidad se está trabajando, simultáneamente con el desarrollo motivo del presente artículo, en la implementación de un algoritmo de clasificación adaptativo basado en redes neuronales utilizando capas ocultas como forma de lograr una mejor caracterización de los patrones de entrada.

Conclusiones:

Se ha presentado una forma de clasificación automática de la población leucocitaria de una muestra de sangre, utilizando técnicas de procesamiento de imágenes y redes neuronales, aún en desarrollo.

Pese a que los ejemplos presentados corresponden a frotis sanguíneo, es posible extender estos conceptos y reutilizar los algoritmos en otros tipos de muestra histológica.

Los resultados pueden proveer una herramienta muy útil en el diagnóstico de patologías muy específicas, como por ejemplo, en el caso del tejido hepático, la modificación de la proporción de los tipos celulares del hígado permitiría diagnosticar si se trata de una fibrosis hepática o de una hepatitis.

La característica más importante del presente trabajo es la posibilidad de contar con una herramienta de clasificación automática y objetiva que reemplace la necesidad de operación manual por un experto.

Toda la documentación se encuentra disponible en el L.I.D.I. (Laboratorio de Investigación y Desarrollo en Informática), 50 y 115 1er. Piso, La Plata.

Bibliografía:

- [BAX] "Digital Image Processing". Gregory A. Baxes. De. Wiley. 1994
- [FAU] "Tratado de Histología". D.W.Faucett. Ed. Mac Graw Hill. 1991
- [FRE] "Redes Neuronales. Algoritmos, aplicaciones y técnicas de programación". Freeman y Skapura. 1993
- [GON] "Digital Image Processing". Rafael González. Addison Wesley. 1992
- [JAI] "Fundamentals of Digital Image Processing". Anil Jain. 1989
- [KAY] "Graphics File Formats". Kay & Levine. 1995
- [LEE] "Hematología Clínica Vol.3 ". Lee, Bithell, Foerster, Athens y Lukens. 1994
- [MAS] "Signal and Image Processing with Neural Networks". Timothy Masters. 1993
- [PAO] "Adaptative Pattern Recognition and Neural Networks" Yoh-Han Pao. 1989
- [RAO] "Neural Networks and Fuzzy Logic". Rao y Rao. 1995
- [WEI]. "Histología". Weiss L. 1986

Um Sistema Híbrido Neuro-Especialista para Apoio à Tomada de Decisão

Analberto Jacques Nunes Seixas
Instituto Militar de Engenharia
Departamento de Informática
Rio de Janeiro - Brasil
e-mail: jacques@ime.eb.br

Antônio Carlos Gay Thomé
Instituto Militar de Engenharia
Dept. de Engenharia Elétrica
Rio de Janeiro - Brasil
e-mail: thome@nde.ufrj.br

SUMÁRIO

Este artigo apresenta de forma sucinta, a pesquisa e o trabalho desenvolvidos para se chegar a um Sistema Híbrido Neuro-Especialista para Apoio à Tomada de Decisão. O texto sugere algumas aplicações para tal sistema bem como um estudo de caso com *dados reais* que se mostraram desafiadores quanto ao seu pré-processamento e adequação ao modelo do Sistema Híbrido. São apresentados, também, os resultados obtidos que demonstram positivamente o sucesso alcançado com o presente trabalho.

No presente momento, o trabalho se encontra em uma segunda versão, na qual se busca melhorar a interface para treinamento do módulo neural, grande responsável pela atualização do conhecimento do Sistema.

1 - INTRODUÇÃO

O problema da tomada da decisão mais adequada e no tempo certo é fator de grande importância em todos os setores do conhecimento humano. Seus principais requisitos são: dispor do conhecimento necessário sobre o assunto e ter uma vasta experiência no setor. Ambos os requisitos são subjetivos, requerem longo tempo de formação específica e larga experiência profissional. A dinâmica e a evolução tecnológica da sociedade atual fazem da "tomada da decisão" um processo ao mesmo tempo complexo e fundamental.

Para lidar com esta complexidade, faz-se necessário o uso de ferramentas de auxílio e de suporte aos processos de análise, simulação e tomada da decisão. É dentro deste contexto que se posiciona o presente Sistema.

Sistemas Especialistas são, até o presente momento, os mais conhecidos e os mais utilizados como suporte à tomada da decisão [PASS93]. Já o emprego de *Redes Neurais* para esta classe de problemas ainda é pouco encontrado na literatura, embora estas apresentem-se, por suas características estruturais e de funcionamento, como uma ferramenta bastante eficiente para aqueles casos em que haja a disponibilidade de um acervo de dados histórico, de onde o conhecimento sobre o assunto possa ser automaticamente extraído com base em evidências passadas e, também, naqueles casos em que os especialistas não estão disponíveis. O emprego de Sistemas Híbridos se apresenta assim, como uma tendência forte na obtenção de modelos mais eficientes e eficazes.

2 - ÁREAS DE INTERESSE

Existe um grande leque de atividades em que um auxílio automatizado à Tomada da Decisão, principalmente levando em consideração o conhecimento e experiência históricos, vem a ser de grande valia, como por exemplo:

- a) A predição de séries temporais no mercado de ações. Trata-se de um problema extremamente complexo, onde não só o comportamento histórico da ação é de capital importância mas também outras informações como a situação política e econômica do mercado, por exemplo, contituem fatores de influência bastante considerável [THOM92].
- b) A análise de risco para empréstimo bancário. É um problema que até agora vem sendo geralmente tratado exclusivamente por Sistemas Especialistas [PASS93], gerados a partir da experiência dos analistas de crédito. Tais sistemas podem ser largamente enriquecidos com a introdução da experiência histórica, que pode ser obtida através do processamento automático dos casos e experiências adquiridas em empréstimos anteriores.

- c) A análise de risco de cobertura de bens móveis ou imóveis. Sabe-se que tal problema não se prende a regras estáticas bem estabelecidas, mas sim a instâncias que dependem muito de fatores econômicos, sociais, regionais, etc. Tais fatores podem ser melhor captados e mantidos atualizados pelo paradigma conexionista através de treinamentos periódicos. Tais treinamentos permitem passar para o sistema a variação apresentada no mercado com a apresentação de novos casos surgidos no período de tempo em vigor para a nova atualização.
- d) A seleção de recursos humanos. Este é um problema que tem sido comumente operacionalizado por meio de testes de natureza psicotécnica e puramente técnica segundo alguns padrões de necessidade validados dentro de um certo contexto. Apesar disso, muitas vezes se observa que indivíduos selecionados são inadequados para a função a que se destinam. Embora não se possa avaliar exatamente o porque desse fato, supõe-se que redes neurais, com uma massa de dados históricos corretamente levantados, poderia propor a não contratação de indivíduos com características semelhantes às de outros que trouxeram problemas em épocas passadas. Caberia ao Sistema Especialista a parte originalmente feita pelos próprios especialistas em seleção de pessoal, qual seja: a análise lógica das características do candidato, comparativamente com as desejadas para a ocupação do cargo vago. Dessa forma, o especialista fica liberado para atividades mais nobres como a preparação de novas baterias de teste, por exemplo. Um trabalho nesta área foi o realizado por Fran Labate e Larry Medsker [LABA93] durante o desenvolvimento de um sistema híbrido para seleção de equipes para tarefas específicas dentro do universo de funcionários de uma determinada empresa.
- e) De modo especial, foi motivação para este trabalho, a necessidade de contribuir para uma melhor seleção dos recursos humanos para as Forças Armadas e em particular para o Exército Brasileiro.

3 - O MODELO SHIATD

O Sistema Híbrido Inteligente de Apoio à Tomada de Decisões é um Sistema que reúne dois paradigmas (Sistemas Especialistas e Redes Neurais) de Inteligência Artificial com a finalidade de auxiliar o Agente Decisor em sua tarefa.

Esquematicamente, o *SHIATD* possui um pré-processador, um comitê de redes neurais, um módulo especialista e uma interface com o usuário que podem ser vistos, em destaque, na Figura 3.1.

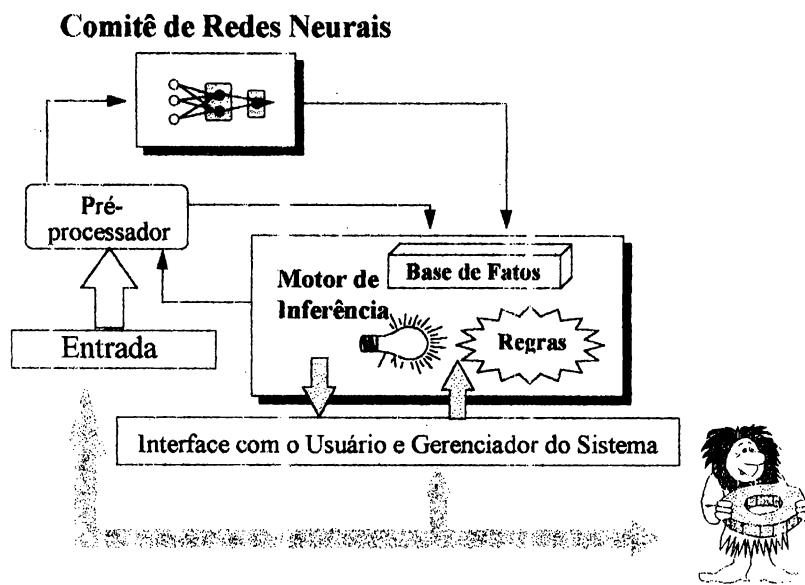


FIGURA 3.1: Esquema esclarecedor das partes componentes do SHIATD.

Aparecem todos os seus componentes, destacando-se as funções, pelas interligações da figura. A Interface proporcionando o “diálogo” entre Sistema Especialista e Usuário; o Pré-processador, adaptando os dados de entrada para os formatos necessários ao Módulo do SE e ao Comitê de Redes Neurais; o Motor de Inferência trabalhando com fatos e regras da base; e o Comitê fornecendo seu pré-diagnóstico como base para a solução final que o Sistema fornecerá em nome de todo o SHIATD (etapa de utilização).

4 - O ESTUDO DE CASO

Para validar o modelo, usou-se como estudo de caso um sistema para apoio à decisão sobre a incorporação ou não de conscritos às fileiras do Exército Brasileiro. Para tanto, foram utilizadas informações históricas obtidas de cadastros de conscritos¹ e, também, suas alterações do período de vida na caserna, que foram utilizadas para se gerar um conceito indicador do grau de adaptação do citado conscrito à vida militar. Com tais dados e a experiência de oficiais e sargentos adquirida na lida com várias turmas de soldados, foram treinadas as redes neurais e elaboradas as regras do sistema especialista, que compõem o SHIATD.

4.1 - Aquisição dos Dados [SEIX96]

Nesta etapa chegou-se a dados de cadastro dos conscritos para a partir deles, serem selecionadas as características de entrada das Redes Neurais e retirar valores para os atributos do módulo Especialista. Levantou-se também a saída para o Módulo Neural que se baseou nos dados disponíveis de alterações² daqueles conscritos no período S.M.I.³. Todos os dados foram relativos aos conscritos selecionados nos anos de 1989 a 1992, que vieram a servir ao Exército nos anos de 1990 a 1993.

Para a geração dos dados de entrada, foi feito um trabalho de "Feature Selection" [THOM93] e de representação de características [LAWR91], chegando-se aos resultados das Figuras 4.1 e 4.2. [SEIX96].

Para a geração dos dados de saída do Módulo Neural, foi feito, inicialmente, um programa que não só facilitou a digitação dos dados de alterações dos soldados, como também interpretava tais dados, valorando-os conforme a experiência de tropa de diversos oficiais, fazendo uma média ponderada pelos tipos e quantidades de ocorrências na ficha de cada soldado, resultando no final, em um valor entre 0 (zero) e 1 (um) que, quanto mais perto de 1, indicava um maior grau de adaptação ao serviço militar. A Tabela 4.1 mostra os resultados alternativos testados neste trabalho.

TABELA 4.1: Representação e Interpretação das saídas avaliadas para as redes neurais.

REDES	Representação da saída	Interpretação da saída	Relação com o grau de comportamento
TIPO 1 (1 saída)	0	mau soldado	Grau < 0.5
	0.5	bom soldado	0.5 <= Grau <= 0.59
	1	ótimo soldado	Grau > 0.59
TIPO 2 (3 saídas)	1 - 0 - 0	mau soldado	Grau < 0.5
	0 - 1 - 0	bom soldado	0.5 <= Grau <= 0.59
	0 - 0 - 1	ótimo soldado	Grau > 0.59
TIPO 3 (1 saída) ⁴	0	contra-indicado a servir	Grau < 0.5
	1	indicado a servir	Grau > = 0.5

¹ Conscrito: cidadão em regime de seleção para o Serviço Militar Inicial (período anterior à incorporação).

² Alterações: relação de todas as ocorrências importantes durante a vida militar do soldado, como punições sofridas, elogios recebidos, a quantas visitas médicas foi, quantos dias ficou baixado e em que época etc.

³ S.M.I. : Serviço Militar Inicial.

⁴ Esta foi a representação final adotada.

DESCRIÇÃO	REPRESENTAÇÃO	
1) VOLUNTÁRIO	1: SIM	0: NÃO
2) FORA DO PRAZO (APRESENTAÇÃO)	1: NÃO	0: SIM
3) PAI / MÃE NÃO DECLARADO (A) (POSSUI ?)	0: POSSUI	1: NÃO
4) ZONA RESIDENCIAL	0: RURAL	1: URBANA
5) UF NASCIMENTO COINCIDE COM A DO SMI?	0: NÃO	1: SIM
6) OCUPAÇÃO (POSSUI ?)	0: NÃO	1: SIM
7, 8, 9) ESCOLARIDADE	000: Analfabeto 010: 1 A 4 Série DO 1G 011: 1 A 4 Série DO 2G 111: Terceiro GRAU	001: Pré-alfabetizado 100: 5 A 8 série do 1G 101: 2G Completo
10) DESEJA SERVIR?	0: NÃO	1: SIM
11) FÍSICO PROBLEMÁTICO? (ALT < 1,60 / P> 80 Kg e ALT < 1,70)	0: SIM	1: NÃO

FIGURA 4.1: Significados e valores das características do vetor de entrada para as Rede Neurais. Estes 11 valores de entrada estão disponíveis para 1821 amostras.

DESCRIÇÃO	REPRESENTAÇÃO	
12 E 13) TIPO DE DISTRIBUIÇÃO	10: NECESSIDADE SV. 01: MAJORAÇÃO	11: FORÇADA
14) ATV. COMBATE (GRAU DE PREFERÊNCIA)	0.00: NÃO PREFERE. 0.65: GRAU 2	0.35: GRAU 3 0.95: GRAU 1
15) ATV. MEC. (GRAU DE PREFERÊNCIA)	0.00: NÃO 0.65: GR 2	0.35: GR 3 0.95: GR 1
16) ATV. BUROC. (GRAU DE PREFERÊNCIA)	0.00: NÃO 0.65: GR 2	0.35: GR 3 0.95: GR 1
17) ATV. ELE / ELO (GRAU DE PREFERÊNCIA)	0.00: NÃO 0.65: GR 2	0.35: GR 3 0.95: GR 1
18) ATV. GERAIS (GRAU DE PREFERÊNCIA)	0.00: NÃO 0.65: GR 2	0.35: GR 3 0.95: GR 1
19 E 20) GRUPO DE DISTRIBUIÇÃO	0.5 0.0: 0 1.0 0.5: 2 0.5 1.0: 4	1.0 1.0: 1 1.0 0.0: 3 0.5 0.5: 5

FIGURA 4.2: Significados e valores das características do vetor de entrada para as Rede Neurais. 356 amostras possuem além das 11 entradas da Figura 4.1, mais estas nove.

4.2 - As Redes e seu Treinamento [SEIX96]

O modelo escolhido para compor o Comitê Neural foi o de *rede feedforward* com treinamento *backpropagation* [ZURA92]. Foram adotados a taxa de aprendizagem adaptativa e momento com o objetivo de acelerar o treinamento e reduzir o risco de oscilação.

A concepção final do Módulo Neural do modelo foi obtida a partir da execução de diversas etapas conforme abaixo:

1. Escolha da representação ideal para a saída das redes neurais (Tabela 4.1);
2. Seleção, a partir dos arquivos de cadastro, das características de entrada mais apropriadas para o problema (Figuras 4.1 e 4.2);
3. Escolha do número de camadas intermediárias e do número de neurônios mais adequados ao caso (Tabela 4.2);
4. O particionamento do espaço de entrada a fim de definir o número de redes para a composição do comitê. (Tabela 4.2) e
5. A escolha do modelo de comitê de redes ideal para o treinamento (Tabela 4.2).

Todos os passos acima citados, encontram-se melhor detalhados em [SEIX96, p. 93 a p. 104].

TABELA 4.2: Características Estruturais do Modelo Neural

Número de Camadas Intermediárias	01
Número de Neurônios na Camada Intermediária	10
Particionamento do Espaço de Entrada	03 “clusters”
Modelo de Comitê Escolhido	Fuzzy

5 - O MÓDULO NEURAL

Foram estudados e treinados os seguintes tipos de comitês: *Winner Takes All* [SEIX96] [THOM93], *Especialista* [SEIX96], e *Fuzzy* [THOM93] [SEIX96].

5.1- Comitê WTA (Winner Takes All)

Baseia-se no algoritmo de clusterização *Hard K-means*⁵ [THOM93,p.14], que assume prévio conhecimento do número de classes (“clusters”) e usa a distância Euclidiana como medida de similaridade. A ideia contida no modelo *WTA* é a do *dividir-e-conquistar*, ou seja, um problema complexo é inicialmente dividido em subproblemas mais simples, que são tratados individualmente. A implementação do modelo é feita em três fases:

- a) Particionamento do Espaço => O espaço de amostras disponíveis para o treinamento do comitê é particionado pelo algoritmo *Hard K-means*, segundo um número pré-determinado de classes. Como resultado do particionamento, obtém-se as amostras e os centróides (centros de massa) de cada classe (“cluster”).
- b) Treinamento => Tantas redes neurais são geradas, quantas forem as classes identificadas no item a. As redes podem ter arquiteturas diferentes e cada uma é treinada de forma independente, com as amostras previamente alocadas para a classe que ela representa.
- c) Teste e Emprego => Dada uma amostra, ela é primeiramente classificada entre as classes existentes, com base na sua distância euclidiana para com os diferentes centróides. A rede correspondente à classe vencedora é, então, selecionada para tratar o vetor de entrada e fornecer a saída do sistema. Na Figura 5.1 observa-se graficamente a constituição do comitê *WTA*. No treinamento, as redes R1, R2 e R3 são treinadas individualmente, respectivamente com as amostras selecionadas para as classes P, Q e R. No emprego do comitê, as classes são substituídas pelos seus respectivos centros de massa, usados na

⁵ Algoritmo que serviu para o desenvolvimento do ISODATA por Ball e Hall [THOM93]

classificação de cada entrada e na seleção da rede a tratar a entrada corrente e a fornecer a saída correspondente.

Como características positivas do modelo *WTA* podem ser citadas:

- A independência das redes e dados, que possibilita a realização de treinamentos e ajustes das redes de forma individualizada e em paralelo; e
- A possibilidade de serem utilizadas redes de diferentes arquiteturas e modelos, que melhor se ajustem ao seu universo particular.

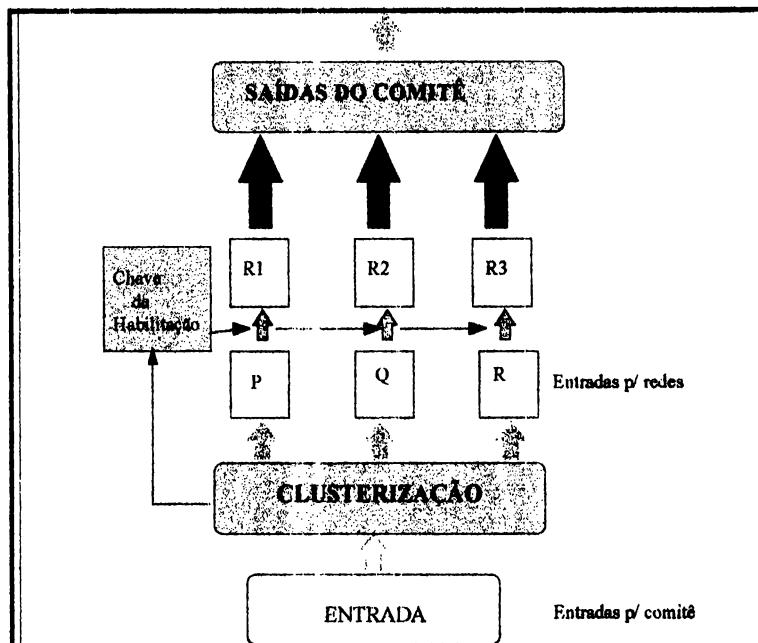


FIGURA 5.1: Esquema de Comitê *WTA*, onde a saída correspondente a cada vetor de entrada é fornecida por uma única rede, selecionada pelo vetor de pertinência fornecido pelo algoritmo de clusterização. Por exemplo, se uma determinada amostra é classificada como pertencendo a classe “Q”, então apenas a rede “R2” é ativada para processar o vetor corrente e fornecer a saída do comitê. Desta forma, cada rede se comporta como uma especialista, possibilitando uma melhor “performance” do comitê como um todo.

5.2- Comitê Especialista

Baseia-se no apelo intuitivo à proficiência pela especialização, ou seja, na expectativa de que se alguém se dedica a observar apenas um aspecto do problema, sua observação será melhor do que se estivesse tentando observar todos os possíveis aspectos ao mesmo tempo. Como exemplo, poderia ser citado o seguinte fato: O controle de qualidade do produto numa fábrica de “whiskey” sendo realizado por duas pessoas, onde uma observa a colocação correta do rótulo e outra a quantidade de líquido na garrafa será mais confiável do que se fosse feito por uma única pessoa a observar o rótulo e a quantidade de líquido.

No comitê Especialista (Figura 5.2), pressupõe-se uma representação múltipla da saída, onde cada neurônio da saída representa uma possibilidade de classificação. No caso em que se quer classificar em duas possibilidades antagônicas como *bom* e *mau*, *indicado* e *contra-indicado*, por exemplo, as redes teriam, então, duas saídas, onde a possibilidade positiva seria “0 - 1” e a contrária seria “1 - 0”. Cada rede, então, é treinada com uma das saídas: a rede especializada em classificar os casos negativos treina com a saída da esquerda enquanto a outra rede treina com a saída da direita. Desta forma, espera-se que cada uma se especialize em perceber os padrões de característica que influem para que o elemento assuma apenas o papel de sua responsabilidade; e, ao serem colocadas lado a lado, uma saída completará a outra, de modo a que se possa confirmar a tendência de cada amostra; ou seja, *não basta o rótulo estar bem posicionado. É necessário que se tenha “whiskey” na medida certa*.

Neste modelo de comitê, são treinadas tantas redes quantos forem os neurônios da camada de saída. Cada rede fornece uma saída que, lado a lado com as demais, formará o universo das saídas esperado.

Na figura 5.2 observa-se graficamente a constituição do *Comitê Especialista*. No treinamento, as redes 1, 2 e 3 são treinadas individualmente. No emprego do comitê as amostras são apresentadas a todas as redes e seus resultados, uma vez em conjunto, são interpretados como a saída do comitê.

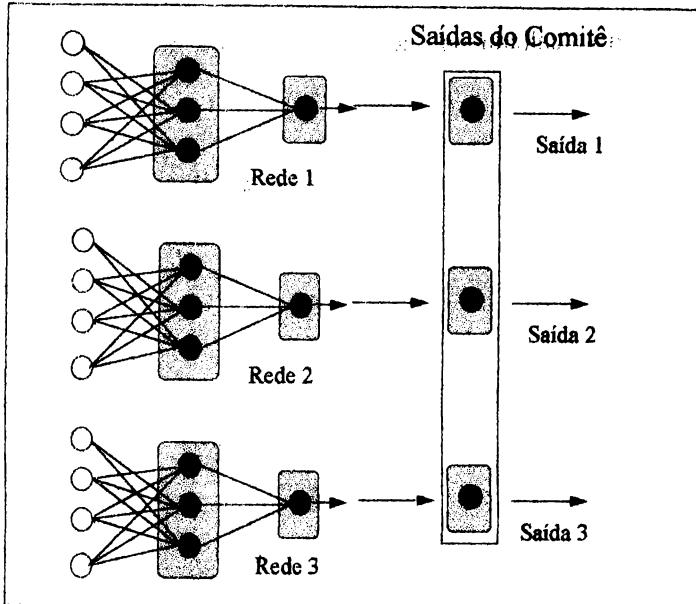


FIGURA 5.2: Esquema de Comitê especialista onde observa-se que cada rede se encarrega de fornecer uma saída para compor, lado a lado, a saída tripla (neste caso) do comitê.

5.3- Comitê Fuzzy (Lógica Nebulosa)

Este tipo de comitê baseia-se no algoritmo de clusterização *Fuzzy C-means*, desenvolvido por Bezdek [THOM93,p.14] que nada mais é que a versão nebulosa (“fuzzy”) do *Hard K-means*. O algoritmo baseia-se na minimização de uma função objetivo, caracterizada pela soma das distâncias aos centros de massa, pelo ajuste de um parâmetro chamado grau de pertinência e pela posição dos centróides, conforme é explicado na Equação 4.1 abaixo:

$$\min J_m(U, V) = \min \left(\sum_{i=1}^n \sum_{j=1}^c \mu_{ij}^m \|X_i - V_j\|^2 \right) \quad (5.1)$$

sujeita a

$$\sum_{j=1}^c \mu_{ij}^m = 1, \quad 1 \leq i \leq n \quad (5.2)$$

$$\mu_{ij}^m \geq 0, \quad 1 \leq i \leq n \quad e \quad 1 \leq j \leq c, \quad (5.3)$$

onde

m	é um escalar maior que 1;
n	é o número de amostras;
$V_j \in \mathbb{R}^d$	é o centróide do cluster j , e “ d ” é a dimensão das amostras;
$\ \cdot\ $	é a norma Euclidiana;
μ_{ij}	é o grau de pertinência da amostra i em relação ao “cluster” j ;
c	é o número de “clusters”;
$X = \{X_i\}$	é a matriz de características das amostras ($d \times n$);
$U = \{\mu_{ij}\}$	é a matriz de pertinência ($n \times c$);
$V = \{V_i\}$	é a matriz de centróides ($d \times c$).

O algoritmo calcula os centros de massa, e os graus de pertinência de acordo com as seguintes equações e regras:

$$V_j = \frac{\sum_{i=1}^n \mu_{ij}^m X_i}{\sum_{i=1}^n \mu_{ij}^m}, \quad (5.4)$$

e

$$\mu_{ij} = \frac{\left(\frac{1}{d_{ij}^2}\right)^{m-1}}{\sum_{l=1}^c \left(\frac{1}{d_{il}^2}\right)^{m-1}}, \quad (5.5)$$

onde

$$d_{ij}^2 = \|X_i - V_j\|^2 \quad (5.6)$$

e

$$\text{se } d_{ii} = 0, \text{ então } \mu_{ii} = 1.$$

A Figura 5.3 mostra os principais passos do algoritmo de forma sumária:

Passo 1	Começar com uma seleção dos graus de pertinência aleatoriamente entre [0,1], satisfazendo $\sum_{i=1}^c \mu_{ij} = 1$;
Passo 2	Calcular os centróides (centros de massa) $V_i(k)$ usando $\mu_{ij}(k)$;
Passo 3	Calcular $\mu_{ij}(k+1)$ usando $V_i(k)$;
Passo 4	Parar caso $f(J_k, J_{k+1}) < \epsilon$, caso contrário, fazer $k \leftarrow k+1$ e voltar ao passo 2.

FIGURA 5.3: Principais passos do algoritmo de clusterização *Fuzzy C-means*.

OBS: Pode ser usado também como critério de parada a função $f(U(k), U(k+1)) < \epsilon$, onde $f(\cdot)$ representa o grau de variação entre a matriz de pertinência na iteração k e a mesma matriz na iteração $k+1$. Se este valor for menor que um mínimo aceitável (ϵ), é sinal que o algoritmo já atingiu um ponto de convergência aceitável.

A idéia contida no modelo *Fuzzy* é a de um corpo de jurados onde cada jurado tem um certo grau de confiabilidade em sua opinião. Desta forma, todos são ouvidos, entretanto, cada um com um peso de confiabilidade tanto maior quanto mais conhecimento do réu ele possuir. A implementação do modelo também é feita em três fases:

- a)Pré-classificação das amostras => As amostras disponíveis para o treinamento do comitê são classificadas pelo algoritmo *Fuzzy C-means de acordo com o número de classes pré-estabelecidas*, gerando os *centróides* e a correspondente *matriz de pertinência* das amostras [THOM93] [SEIX96].
- b) Treinamento => Dada uma amostra, ela é passada pelo algoritmo *Fuzzy C-means* de modo a que receba um grau de pertinência em relação a cada classe existente. Ela é, então, treinada por todas as redes (cada uma referente a uma *classe específica*) e a combinação final é feita, fazendo-se uma média ponderada das saídas de cada rede pelo grau de pertinência que a referida amostra possui em relação a cada *classe*. Só então o erro pode ser calculado e a retropropagação do mesmo pode ser feita. Esta

retropropagação do erro começa multiplicando o valor do erro respectivamente pelos mesmos graus de pertinência de forma a que cada rede retropropague a parcela do erro que a si pertence.

c) Teste e Emprego => É feito apenas o *forward* do treinamento, obtendo-se a saída como a resposta do comitê.

Na figura 5.4 observa-se graficamente a constituição do comitê Fuzzy em regime de treinamento. As redes R1, R2 e R3, são treinadas com todas as amostras e suas saídas são ponderadas segundo os graus de pertinência que o algoritmo de clusterização indicou.

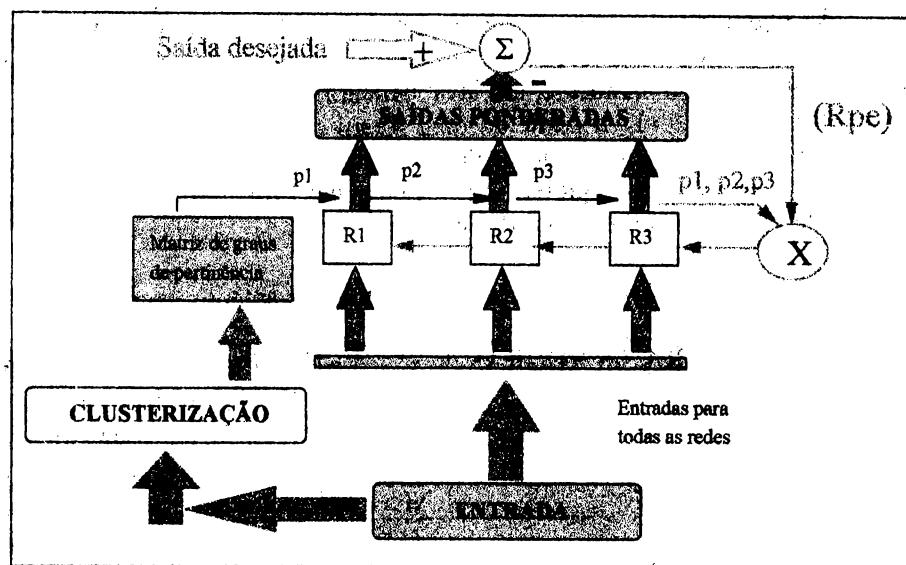


FIGURA 5.4: Esquema de treinamento do Comitê FUZZY, onde todas as redes treinam todas as entradas e fazem a composição da saída conforme o grau de pertinência de cada entrada em relação a cada classe, representada pela rede. Na retropropagação do erro, também o grau de pertinência é considerado para que cada rede retropropague tão somente a sua parcela no erro total.

Os testes mostraram que o comitê Fuzzy com três redes, cada uma com 10 neurônios na camada intermediária, era o que melhores resultados apresentava, conforme é visto na Figura 5.5, ao lado.

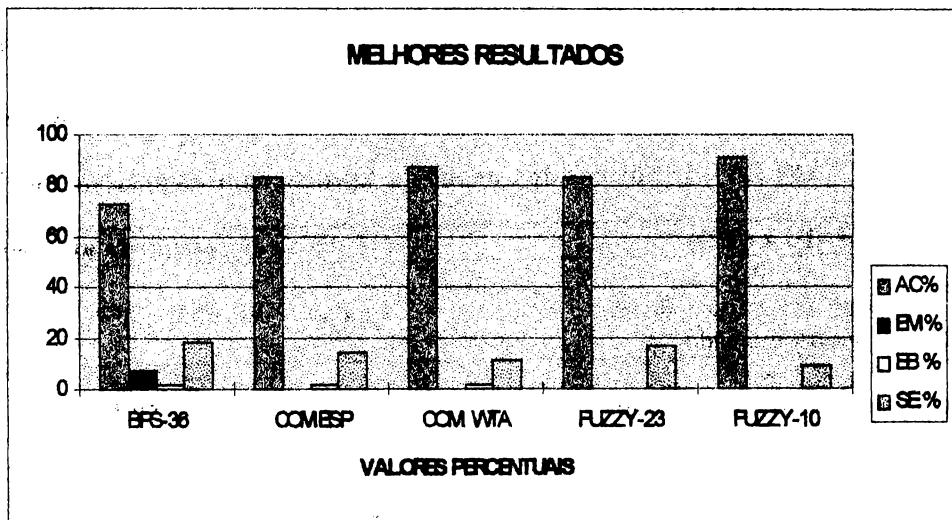


FIGURA 5.5: Melhores resultados de cada modelo, onde: BPS-36 é uma rede BP simples com Taxa de Aprendizado adaptativo e Momento com 36 neurônios na camada intermediária; COM ESP é um comitê especialista com cada rede BP composta por 10 neurônios na camada intermediária; COM WTA é um comitê Winner Takes All também com 10 neurônios na camada intermediária; e FUZZY são os comitês Fuzzy de 23 e 10 neurônios. Justifica-se a escolha do comitê FUZZY-10 como o componente para o SHIASP com grande facilidade, pois observa-se que ele supera os demais em acertos e em erros, além de levar menos dúvidas para o Sistema Especialista.

6 - O MÓDULO ESPECIALISTA

Para o desenvolvimento deste sistema, foi utilizado um SHELL bastante recente que facilitou o desenvolvimento das interfaces, devido ao acesso obtido ao código fonte [TEIX95].

As regras para o sistema foram obtidas de duas formas distintas que se completaram: uma pesquisa entre os responsáveis pelas seleções inicial e complementar do conscrito para que se obtivesse a sua opinião e, adicionalmente, um levantamento estatístico em função dos atributos levantados pelos especialistas (Tab. 6.1) , a partir do qual foram obtidas as probabilidades do conscrito ser *contraindicado*, condicionadas aos valores dos seis atributos selecionados pelos especialistas como os mais importantes para a análise global. Tal levantamento foi feito com os dados não utilizados, quer em treinamentos quer em testes das redes neurais.

TABELA 6.1: Relação de Atributos Levantados para o Módulo Especialista

SIGLA PARA AS REGRAS	SIGNIFICADO DO ATRIBUTO
M	Tem Pai e / ou Mãe não declarado(s)
U	Mora em zona Urbana
O	Tinha Ocupação anterior à incorporação
B	Nível de Escolaridade inferior à 5ª série do 1º grau
G	Gosta de atividades de combate?
D	Grau (Grupo) de distribuição abaixo de 4??

7 - O FUNCIONAMENTO COOPERATIVO

1. Extração das características necessárias para as entradas do Comitê Fuzzy;
2. Extração dos valores dos atributos necessários ao Módulo Especialista;
3. Processamento das características, por parte do *Comitê Fuzzy*, gerando uma saída (chamada de PD⁶) entre 0 (ZERO) e 1(HUM) que, dependendo de seus limites, indicará para a interface entre o Comitê e o SE a forma cálculo da aptidão, mostrada na Tabela 7.1;
4. A interface calcula e exterioriza a aptidão no monitor, arquivo magnético e/ou impressora.

TABELA 7.1: Formas de Cálculo da Aptidão emitida pelo Sistema Híbrido

SAÍDA (PD)	Formas de cálculo da aptidão
0 - 0.5 O Comitê tem certeza de ser contra-indicado.	$\text{aptidão} = 100 - (55 + 90 * (0,5 - PD))$
0.7 - 1.0 O Comitê tem certeza de ser Indicado.	$\text{aptidão} = 100 - (150 * (1 - PD))$
0.5 -- 0.7 Caracteriza a dúvida do Comitê. Neste caso, o SE é acionado e as duas opiniões são consideradas, embora a do SE tenha peso dobrado.	O Sistema Especialista entra em ação e gera o seu diagnóstico(PCI ⁷); então a aptidão é calculada como se vê: $\text{aptidão} = 100 - \left(\frac{(45 + 50(0,7 - PI)) + 2 * PCI}{3} \right)$

8 - RESULTADOS OBTIDOS

1. Os treinamentos foram feitos com 301 amostras dentre as 355 completas (com todas as características necessárias ao treinamento).

⁶ PD : Pré - Diagnóstico do Comitê Fuzzy.

⁷ PCI : Probabilidade de ser Contra -Indicado.

2. Foram reservadas as outras 54 amostras para serem utilizadas em teste que pudesse demonstrar a “performance” das redes e do sistema híbrido como um todo.

3. A comparação entre todas as redes e outros modelos de comitês testados [SEIX96] que foi mostrada na Figura 5.5, se vale dos Acertos imediatos (AC) aos quais a rede ou comitê chega, dos Erros em considerar Indicado um conscrito que deveria ser contra-indicado (EM) (pior dos erros), dos Erros em considerar contra-indicado um conscrito que deveria ser indicado (EB) e das dúvidas, que fazem com que o SE dê o seu parecer para a “aptidão” final (SE).

4. Os resultados finais do Sistema Híbrido trabalhando com o comitê vencedor são mostrados na Figura 8.1. A coluna “ESP” mostra o valor conhecido do conscrito onde 1 = indicado e 0 = contra-indicado; a coluna “PD” mostra o valor da saída do comitê; a coluna “PCI” recebe “X” quando não houve dúvida por parte do módulo Neural e, portanto, o SE não entra em ação, e recebe um valor de Probabilidade de ser Contra-Indicado dado pelo SE quando o mesmo é empelhado (no caso de dúvida do módulo Neural).

As colunas “APT”⁸ e “CF” mostram, respectivamente, a “aptidão” final dada pelo sistema híbrido e o consequente conselho representado por 1 (indicado) ou por 0 (contra-indicado).

NR	ESP	PD	PCI	APT	CF	NR	ESP	PD	PCI	APT	CF
1	1	0,79	X	68	1	28	1	1,00	X	100	1
2	1	0,96	X	94	1	29	1	0,93	X	89	1
3	1	1,00	X	100	1	30	1	0,80	X	70	1
4	1	1,00	X	100	1	31	1	0,99	X	98	1
5	1	0,94	X	90	1	32	1	1,00	X	100	1
6	1	0,95	X	92	1	33	1	1,00	X	100	1
7	1	1,00	X	100	1	34	1	1,00	X	100	1
8	1	0,97	X	95	1	35	0	0,13	X	12	0
9	1	1,00	X	99	1	36	1	0,98	X	97	1
10	1	0,71	X	57	1	37	1	0,98	X	97	1
11	1	1,00	X	100	1	38	1	0,71	X	57	1
12	1	0,74	X	61	1	39	1	1,00	X	99	1
13	1	0,66	0	84	1	40	1	1,00	X	99	1
14	1	1,00	X	100	1	41	0	0,13	X	12	0
15	1	0,96	X	95	1	42	1	0,78	X	68	1
16	0	0,49	X	44	0	43	0	0,37	X	34	0
17	1	0,97	X	95	1	44	1	0,97	X	95	1
18	1	1,00	X	100	1	45	1	1,00	X	100	1
19	1	1,00	X	100	1	46	0	0,43	X	39	0
20	1	1,00	X	100	1	47	0	0,26	X	23	0
21	1	1,00	X	100	1	48	0	0,67	60	44	0
22	1	1,00	X	99	1	49	1	1,00	X	100	1
23	1	0,99	X	99	1	50	0	0,57	60	43	0
24	1	1,00	X	100	1	51	1	0,98	X	97	1
25	1	0,81	X	72	1	52	0	0,67	60	44	0
26	1	1,00	X	100	1	53	0	0,26	X	23	0
27	1	1,00	X	100	1	54	0	0,57	60	43	0

FIGURA 8.1: Resultados esperados (ESP) e obtidos com o SHIASP. A coluna “PD” mostra os valores dados pelo comitê Fuzzy aos 54 elementos do teste; a coluna “PCI” mostra o valor dado pelo Sistema Especialista, quando solicitado pela dúvida do comitê; a coluna “APT” mostra a conclusão final do sistema, após “ponderar” os dois componentes (conexionista e simbólico) e por fim, a coluna CF mostra a conclusão a que chegaria o agente decisor: Com o comitê Fuzzy unido ao SE, o acerto total foi de 100%.

⁸ APT : Aptidão dada pelo “Sistema Híbrido Inteligente de Apoio à Seleção de Pessoal”.

REFERÊNCIAS BIBLIOGRÁFICAS:

- [LABA93] LABATE, Fran & MEDSKER, Larry. *Employee Skills Analysis Using a Hybrid Neural Network and Expert System*; Geodynamics Corporation and The American University. IEEE, USA, 1993.
- [LAWR91] LAWRENCE, Jeannette. AI Expert Magazine, 1991, novembro, páginas 34-41.
- [PASS93] PASSOS, E. P. L. *Sistema Especialista para Análise de Crédito*, 1993.
- [SEIX96] SEIXAS, Arnalberto Jacques Nunes. *Sistema Híbrido Inteligente de Apoio à Tomadas de Decisões (SHIATD)*; Dissertação de Mestrado. IME, Rio - RJ, 1996.
- [TEIX95] TEIXEIRA, César Bezerra. *GSEOO, Ambiente para Desenvolvimento de Sistemas Especialistas com Bases de Conhecimento que Suportam Herança*; Dissertação de Mestrado. IME , Rio - RJ,1995.
- [THOM92] THOMÉ, Antônio C. G. *Economic Signal, Modelling and Estimation Through a Similarity Based Approach*; paper publicado no Anais do IX Simpósio Brasileiro de Inteligência Artificial, RJ, Set 1992, páginas 66-78.
- [THOM93] THOMÉ, Antônio C. G. *Massively Parallel Nonlinear System Identification Techniques: A Committee Architecture*; Tese de Doutoramento (Ph. D.). Purdue University, Purdue (EUA), 1993.
- [ZURA92] ZURADA, Jacek M. *Introduction to Artificial Neural System*; West Publishing Company, U.S.A., 1992