

# Sistema híbrido inteligente para classificação e tomada de decisão de imagens de satélite

Marcelo Henrique Essado de Moraes<sup>1</sup>

Ernesto Araujo<sup>1,2</sup>

<sup>1</sup> Instituto Nacional de Pesquisas Espaciais

Av. dos Astronautas, 1758. 12227-010, São José dos Campos-SP, Brasil

messado@dem.inpe.br, ernesto.araujo@lit.inpe.br

<sup>2</sup> Universidade Federal de São Paulo (UNIFESP)

Rua Botucatu, 740. 04023-900, São Paulo-SP, Brasil

ernesto.araujo@unifesp.br

**Abstract.** This paper describes an intelligent system for processing images obtained by earth resource satellites. This hybrid computational intelligent approach merges neural and fuzzy approaches in a neuro-fuzzy decision system for visual-driven decision making and pattern recognition. This intelligent hybrid system employs, first, a neural system for image classification in charge of extracting information through a mapping from visual input to output datum. Once the result is obtained by the neural classification the output data is furnished as input to the fuzzy decision support system for dealing with inherent uncertainty and imprecision present in the available information. A comparison of the neural classifier system is exploited to validate the mechanism and advantages of the role system are discussed in a complementary manner. This paper aims to demonstrate the technical viability of the computational intelligence model based on a hybrid system when dealing with images from earth resource satellites.

**Keywords:** remote sensing, image processing, neuro-fuzzy system sensoriamento remoto, processamento de imagens, sistema neuro-fuzzy.

## 1. Introdução

O Brasil é um país florestal com aproximadamente 4,8 milhões de quilômetros quadrados de florestas, o que representa em torno de 10% do total mundial e a segunda maior área de florestas do mundo. As florestas brasileiras abrigam a maior diversidade biológica do Planeta e contribuem de maneira notável na conservação de recursos hídricos, regularização da vazão dos rios, manutenção de encostas e minimização dos riscos de assoreamento dos rios e lagos, entre outros. Além disso, essas florestas abrigam imensos estoques de carbono e, por isso, desempenham uma função estratégica na regulação do clima regional e global. O setor florestal brasileiro representa cerca de 4% do PIB brasileiro. E, finalmente, essas florestas são vitais para milhões de brasileiros que as habitam, os quais dependem dos seus produtos e serviços ambientais (FEDERAL, 2008).

É comum encontrar em livros, relatórios ou artigos a causa subjetiva dos impactos ambientais. De acordo com (SHEPARD, 2005), esta subjetividade pode ser quantificada e tratada através de um rigor matemático e avançadas técnicas de inteligência computacional, dos quais procedimentos desta natureza visam agir de maneira imparcial a questões geográficas, jurisdição política, variação social ou ainda práticas de agências reguladoras induzindo, assim, a uma tomada de decisão baseado em fatos e não idéias. O Brasil visa, a partir de ações concretas no âmbito do governo federal, estabelecer um completo zoneamento agroecológico do país para definir quais áreas agricultáveis podem ser destinadas à produção de biocombustíveis, alimentos ou ainda áreas de preservação ambiental. Em um discurso proferido para as Nações Unidas no ano de 2007 o Presidente da República reitera, "é plenamente possível combinar biocombustíveis, preservação ambiental e produção de alimentos"(SILVA, 26 de setembro de 2007).

O aquecimento global é um grande problema ambiental do século, desafiando a humanidade e a ciência a encontrar soluções técnicas e a buscar outros estilos de produção, consumo

e convivência. Em termos econômicos, estudos indicam que o aquecimento pode causar o mais profundo e extenso dano à economia mundial (FEDERAL, 2008). Sabe-se que a floresta amazônica é uma das áreas que mais poderão sofrer com o aquecimento do planeta. O Plano Nacional sobre Mudança do Clima (PNMC), elaborado pelo governo federal, visa a redução das taxas de desmatamento na Amazônia brasileira por meio de um conjunto de ações integradas de ordenamento territorial e fundiário, monitoramento e controle, fomento a atividades produtivas sustentáveis, envolvendo parcerias entre órgãos federais, governos estaduais, prefeituras, entidades da sociedade civil e o setor privado. Desta maneira, no intuito de desenvolver uma metodologia e técnica para auxiliar no planejamento e monitoração de atividades visando o uso de recursos naturais este trabalho apresenta um sistema híbrido inteligente para classificação e tomada de decisão de imagens de satélite. Uma Rede Neural Artificial (RNA) e um sistema baseado em lógica fuzzy e teoria dos conjuntos nebulosos são apresentados de modo que se possa explorar os melhores resultados obtidos pela junção das duas técnicas. O classificador neural (CN) fornece os dados da imagem ao sistema difuso o qual processa as incertezas e imprecisões obtidas no resultado da classificação e na obtenção da imagem pelo satélite. O sistema neural extrai a informação através de um mapeamento visual dos dados de entrada feitos por um especialista que indica a quantidade e quais classes ou padrões compõem a imagem. Através dos dados de saída do CN é, então, obtida uma função de pertinência que é aplicada como entrada para o sistema difuso, o qual remete a uma tomada de decisão baseada nas variáveis linguísticas.

O processo de classificação consiste na extração de informação em imagens para reconhecer padrões e objetos homogêneos, o que vem sendo amplamente divulgado em ambientes industriais, uma vez que as Redes Neurais Artificiais vem se mostrando cada vez mais eficientes no uso de técnicas para controle, reconhecimento de padrões e processamento de imagens (BASHEER; HAJMEER, 2000), (SCHALKOFF, 1991).

De forma a garantir um custo baixo com qualidade e confiabilidade, uma vez que os departamentos envolvidos em sensoriamento remoto trabalham com mais de 200 mil registros e mais de 10 mil espécies de fauna e flora coletados e estudados durante meses o sistema neuro-fuzzy não visa substituir o especialista, mas sim apoiá-lo até que seja possível automatizar, por completo o tratamento de imagens desta natureza. A técnica empregada neste artigo visa explorar, em caráter multidisciplinar, oportunidades de exploração e integração de diferentes áreas como: engenharia ambiental, cartografia, sensoriamento remoto, políticas públicas e outras áreas científicas como sociologia e antropologia promovendo uma visão sistêmica do estudo.

A automação de processos requer extrema precisão de manipulação de imagens para detecção de alvos em imagens de satélite, sistemas que requerem uso de tecnologia de realidade virtual e tarefas que exigem simulações extra-sensoriais que permitem à máquina tratar informações imprecisas e incertas (SIMÕES A. H. R. COSTA, 2001), (KAWAOKU J. E. ARAUJO, 2005), (FAUSETT, 1994), (HOFFMANN, 2002), (HAYKIN, 1998).

A partir dos resultados obtidos uma comparação entre o CN e outros dois trabalhos é realizada. Para a mesma imagem utilizou-se técnicas de inteligência computacional diferentes, concluindo que o sistema neuro-fuzzy utilizado pode ser empregado para satisfazer necessidades de diferentes grupos.

## **2. Identificação e Modelagem**

A imagem utilizada neste trabalho situa-se no nordeste do Planalto Rio-Grandense, cerca de 139 Km da capital do Estado (Porto Alegre) e inclui grande parte da Floresta Nacional de São Francisco de Paula, considerada a unidade de preservação mais antiga do Estado do Rio Grande

do Sul.

A Figura 1 apresenta um panorama geral da localização da área em questão. A Floresta Nacional de São Francisco de Paula constitui uma Unidade de Conservação (UC) de uso sustentável, caracterizando-se como uma área com cobertura florestal de espécies predominantemente nativas. O objetivo deste tipo de Unidade de Conservação é compatibilizar a conservação da natureza com o uso sustentável dos seus recursos naturais e estimular a pesquisa científica. Suas principais atividades estão centradas na exploração de produtos e sub-produtos florestais, tais como: madeira, erva-mate e sementes de Araucária, bem como educação ambiental, convervação e preservação do patrimônio natural. São encontradas nesta UC reflorestamentos de Araucária Angustifólia, *Pinus taeda* e *Pinus elliotti*, *Eucalyptus* e outras essências com fins comerciais totalizando uma cobertura de pouco mais de 600 ha (hectare). Contudo, a floresta nativa ocupa mais de 900 ha com pequenos trechos de campo nativo e banhado.

A Figura 2 é obtida a partir de 3 bandas do sensor CCD do satélite CBERS 1 (Satélite Sino-Brasileiro de Recursos Terrestre, China-Brazil Earth Resource Satellite) para testar e validar o procedimento adotado. Uma descrição mais detalhada da imagem pode ser obtida em (RUBERT V.T. DIVERIO, 2005).

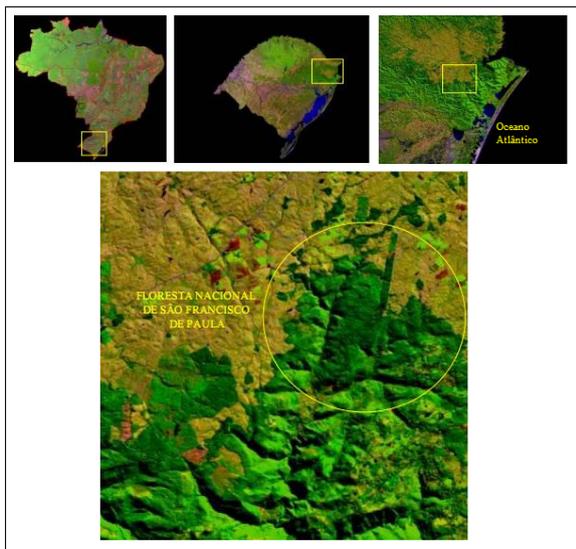


Figura 1: Localização da Floresta Nacional de São Francisco de Paula.



Figura 2: Imagem de teste obtida a partir da composição RGB do satélite CBERS 1.

Após a identificação das características da região, seu uso e propósito, iniciou-se a modelagem do sistema. O sistema neuro-fuzzy apresentado neste trabalho é uma tentativa de satisfazer os requisitos da região analisada e de buscar um novo mecanismo para classificação e tomada de decisão de imagens de satélite.

A Figura 3 apresenta, de maneira didática, um diagrama do sistema neuro-fuzzy. Após a imagem ser obtida do satélite, já com ruído e, por isso mesmo, com imprecisão, é então mapeada para o CN que, por sua vez, gera níveis de classificação para cada padrão da imagem. Após esta primeira etapa, os níveis de classificação são codificados através das funções de pertinência e servem como entradas para o Sistema Difuso de Suporte a Decisão (DSS, *Decision Support System*). Este sistema de Suporte a Decisão foi inspirado em um trabalho anterior cujo aplicação

era de ajuste automático de foco de uma video-câmera em um ambiente industrial (KAWAOKU J. E. ARAUJO, 2005).

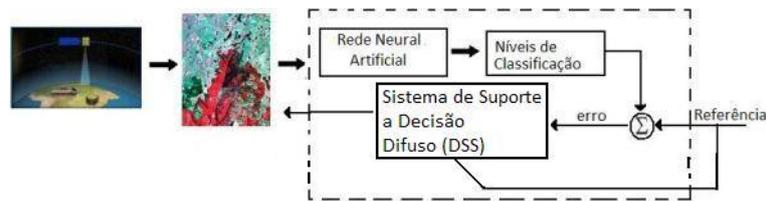


Figura 3: Diagrama do sistema neuro-fuzzy.

## 2.1. Classificador Neural

O classificador neural tem por finalidade classificar a imagem em 8 padrões previamente definidos. Este processamento é realizado através de uma rede neural artificial de múltiplas camadas com retropropagação do erro, a qual foi adotada com base no seu extensivo uso na resolução de problemas complexos e seu método de gradiente descendente para minimizar o erro quadrático da saída da rede a um custo computacional baixo. A arquitetura da rede neural utilizada para o processo de reconhecimento e classificação dos padrões foi a *feedforward* enquanto o ajuste dos pesos de treinamento são feitos com o algoritmo de aprendizado conhecido como Regra Delta (HAYKIN, 1998). A vantagem deste procedimento é justamente sua capacidade de lidar com sistemas não-lineares, processamento paralelo, tolerância a falhas e capacidade de generalização.

A Figura 4 apresenta a arquitetura do CN. Constituída de 3 neurônios de entrada, um para cada banda CCD que formam o padrão RGB de cores, 24 neurônios na camada intermediária e 8 neurônios de saída relativos aos oito padrões: araucaria, floresta nativa, pinus, campo, solo, estrada, nuvem e sombra. O sinal de saída é normalizado no intervalo  $[-1,1]$  com a tangente hiperbólica como função de ativação, onde cada elemento desta camada representa uma determinada classe, impossibilitando a existência de classes não identificadas, pois cada padrão apresentado é associado ao neurônio de maior ativação.

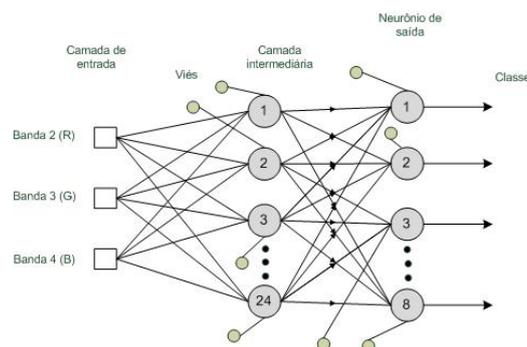


Figura 4: Arquitetura do Classificador Neural.

Identificada a arquitetura da rede neural artificial é necessário iniciar o treinamento da rede. O conjunto de treinamento seguiu através de 54 pontos/classe. A condição de parada foi baseada em dois componentes, no tempo e no erro médio quadrático. As estimativas adotadas foram: o tempo de 40000 épocas e o erro médio quadrático igual a 0.001. Após o treinamento iniciou-se o processo de simulação para validar o CN. Para a simulação da rede foram utilizados uma amostra de 108 pontos/classe diferentes daqueles do treinamento.

Tabela 1: Resultado da classificação.

	C1	C2	C3	C4	C5	C6	C7	C8
Araucaria	74	0	30	0	0	0	2	2
Nativa	0	108	0	0	2	0	1	3
Pinus	19	0	60	0	0	0	0	11
Campo	0	0	0	104	0	12	3	0
Solo	0	0	0	4	106	0	0	0
Estrada	0	0	0	0	0	92	6	0
Nuvem	0	0	0	0	0	4	98	0
Sombra	15	0	18	0	0	0	0	92

Com a classificação da imagem aTabela 1 foi gerada. Com esta tabela é possível comparar o método utilizado para o CN com os dois trabalhos anteriores, (RUBERT V.T. DIVERIO, 2005) e (DRUMMOND, 2004) que utilizaram a mesma imagem apresentada na Figura 2. Para efeito de comparação dos resultados a mesma métrica foi utilizada em todos os trabalhos. Em (RUBERT V.T. DIVERIO, 2005), através de um modelo neural integrando três sistemas: um perceptron de múltiplas camadas, uma rede LVQ (*Learning Vector Quantization*) e uma RBF (*Radial Basis Function*), o autor obteve um índice Kappa de 77,2%, enquanto (DRUMMOND, 2004), aplicando um algoritmo de classificação baseado em um método possibilista chegou a 84,7%. Já o CN modelado neste trabalho apresentou um índice de conformidade Kappa de 82,8%. Este resultado permite concluir que, para esta imagem em particular, a eficiência da rede neural adotada e a qualificação dos dados de treinamanto e teste foram satisfatórios.

## 2.2. Sistema de Decisão Difuso

De posse das informações e das necessidades da região iniciou-se o processo de modelagem do sistema de decisão difuso, o qual levou em consideração a área de cada classe existente sobre o total da imagem e os respectivos fins de cada padrão. Duas das dificuldades encontradas na identificação dos parâmetros deste sistema e que influi diretamente no processo de decisão, são: a capacidade de abstração da rede neural e a própria região em si. Observando a Tabela 1 verifica-se que houve uma certa dificuldade do algoritmo em tratar as classes 1 e 3, pois são dois tipos de árvores parecidas visualmente, ilustrando perfeitamente a imprecisão e incerteza da informação e, conseqüentemente, a importância de um sistema de decisão orientado pela lógica fuzzy.

Nesta etapa foram realizados quatro experimentos para validar as informações obtidas da junção do CN com o sistema de decisão difuso. Por se tratar de uma região de preservação ambiental e exploração de recursos naturais buscou-se emular um especialista humano para a tomada de decisão sobre as classes existentes. Com base nestas restrições (propósito de cada classe) estabeleceu-se o universo de discurso em um intervalo de [-1,3], o operador de implicação Produto Larsen e o operador Mandani-min. Para a decodificação (*defuzzyficação*) utilizou-se o método Centro de Áreas (COA).

A Figura 5 apresenta as características de duas simulações com diferentes funções de pertinência. Ambas utilizam as mesmas regras (base de conhecimento), as mesmas variáveis linguísticas de entrada e os mesmos termos de decisão. No entanto as funções de pertinência assumem formas diferentes. A primeira com funções triangulares e trapezoidais e a segunda com funções gaussianas. Este processo foi adotado, pois as funções de pertinência visam estabelecer certos critérios para a exploração dos recursos e possibilidades de implementação de políticas públicas na região. A Figura 5(a) apresenta as variáveis linguísticas de entrada:

Tabela 2: Resultados do sistema difuso

N.	Função de Pertinência	Variáveis de entrada	Termos de saída	Valor de saída	Tempo (s)	Decisão
1	Triangular e Trapezoidal	4	4	-0,3574	940	Extrair
2	Gaussiana	4	4	0,5838	344	Preservar
3	Triangular e Trapezoidal	4	3	-0,3633	1250	Extrair
4	Gaussiana	4	3	0,3665	625	Preservar

araucaria, nativa, pinus e outros, definidas através das funções triangulares e trapezoidais, enquanto (b) a sua correspondência com funções gaussianas. Em (c) e (d) aparecem os termos linguísticos de decisão: extrair, preservar, avaliar e desconsiderar. Em (e) e (f) é possível verificar a base de conhecimento e em (g) e (h) a medida incerta sobre ela. Em (i) e (j) vê-se outra visão da medida sobre a base de conhecimento e, por fim, (k) e (l) apresentam a resposta do sistema. Para a Figura 5(k) tem-se o valor -0,35 e para a Figura 5(l) tem-se 0,58.

As regras utilizadas para este par de simulação são apresentadas a seguir:

- Regra 1: Se ( $x_1$  é Araucaria) então ( $y$  é Extrair).
- Regra 2: Se ( $x_1$  é Pinus) então ( $y$  é Extrair).
- Regra 3: Se ( $x_1$  é Nativa) então ( $y$  é Preservar).
- Regra 4: Se ( $x_1$  é Outros) então ( $y$  é Desconsiderar).
- Regra 5: Se ( $x_1$  é Araucaria) e ( $x_2$  é Pinus) então ( $y$  é Extrair).
- Regra 6: Se ( $x_1$  é Araucaria) e ( $x_2$  é Nativa) então ( $y$  é Avaliar).
- Regra 7: Se ( $x_1$  é Araucaria) e ( $x_2$  é Outros) então ( $y$  é Extrair).
- Regra 8: Se ( $x_1$  é Pinus) e ( $x_2$  é Nativa) então ( $y$  é Avaliar).
- Regra 9: Se ( $x_1$  é Pinus) e ( $x_2$  é Outros) então ( $y$  é Extrair).
- Regra 10: Se ( $x_1$  é Nativa) e ( $x_2$  é Outros) então ( $y$  é Preservar).

Na Figura 6 é apresentada o segundo conjunto de simulações. A diferença entre este conjunto e o anterior são a base de regras do sistemas e os termos linguísticos de saída. Neste conjunto o termo Avaliar foi retirado no intuito de verificar o impacto na resposta do sistema. Desta forma as regras 6 e 8 foram substituídas e onde lê-se Avaliar, foi alterado para Preservar.

Neste caso a saída, Figuras 6(k) e 6(l), do primeiro teste com as funções triangulares e trapezoidais foi bem próxima à anterior com o valor -0,36. Já, para as funções gaussianas o valor de decisão foi de 0,36, bem diferente do anterior. Analisando estes resultados é possível quantificar qual a melhor abordagem entre as estudadas. A Tabela 2 apresenta a comparação dos conjuntos de simulação. O item 1 e 2 correspondem a Figura 5, respectivamente. Enquanto os itens 3 e 4 à Figura 6. Um fator importante ainda de ser verificado na Tabela 2 é o tempo computacional para cada simulação em segundos. Fator decisivo na computação.

Com os resultados obtidos das simulações, verifica-se, através de análise comparativa entre os termos de decisão do sistema difuso da Tabela 2 e do resultado da classificação do CN na Tabela 1 que a saída correta é Preservar, pois a classe Nativa foi totalmente reconhecida, isto é, dos 108 pontos/classe apresentados ao CN, todos foram identificados. Desta forma, a contribuição desta classe foi bem superior que as outras.

### 3. Conclusão

Foi apresentado neste trabalho um sistema neuro-fuzzy para classificação e tomada de decisão de imagens de satélite. A imagem utilizada foi baseada em trabalhos anteriores e teve por finalidade avaliar as informações geográficas da região, com base nos objetivos de cada classe. Diferentemente dos trabalhos anteriores o objetivo desta metodologia é viabilizar uma nova técnica de recursos computacionais inteligentes para o processamento de imagens, no sentido amplo do termo.

O classificador neural, responsável por classificar a imagem nos padrões previamente estabelecidos, se mostrou bastante eficaz em comparação com outros métodos. O sistema difuso, parte crítica na modelagem do sistema, pois necessita de um conhecimento prévio da região em análise, trouxe conformidade com os resultados esperados.

O principal objetivo da técnica de prover informação útil a partir de uma imagem de satélite de recursos terrestres foi atingido, demonstrando a viabilidade deste sistema híbrido. É possível explorar novos parâmetros neste sistema a fim de melhorar ainda mais os resultados. Trabalhos atuais indicam que outros operadores podem ser utilizados, inclusive a influência do método de decodificação utilizado - Centro de Áreas - o que se mostrou importante na obtenção do resultado, indicando que outras possibilidades podem ser testadas. Outra possibilidade ainda é dividir a imagem em regiões de interesse (ROI, *Regions Of Interest*) de modo que se tenha uma especificação exata de cada parcela da imagem.

### Referências

- BASHEER, I. A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design and application. *J. Microbiological Methods*, v. 43, p. 3–31, 2000.
- DRUMMOND, S. S. I. A clustering-based possibilistic method for image classification. *Advances in Artificial Intelligence, SBIA*, 2004.
- FAUSETT, L. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. [S.l.]: Florida Institute of Technology, Erehwon, NC, 1994.
- FEDERAL, C. I. s. M. d. C. G. *Plano Sobre Mudança do Clima - PMNC*. [S.l.], 2008.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. [S.l.]: Prentice-Hall, 1998.
- HOFFMANN, L. T. R. A. G. G. A. T. Mapeamento de matas com araucária angustifolia utilizando um sistema de informação geográfica. *Mostra de Iniciação Científica UNISINOS*, v. 60{-60}, 2002.
- KAWAOKU J. E. ARAUJO, K. H. K. L. M. F. M. Hybrid visual-driven decision support system in vídeo monitor manufacturing. *Proc. 16th IFAC World Congress*, 2005.
- RUBERT V.T. DIVERIO, J. D. S. S. C. Sistema neural integrado para a identificação de alvos em imagens de satélites. *XII SBSR - Simpósio Brasileiro de Sensoriamento Remoto*, 2005.
- SCHALKOFF, R. J. *Pattern recognition: statistical, structural and neural approaches*. [S.l.]: John Wiley, New York, 1991.
- SHEPARD, R. B. *Quantifying Environmental Impact Assessments Using Fuzzy Logic*. [S.l.]: Springer, 2005.
- SILVA, L. I. L. da. O Brasil não abdica da soberania na Amazônia. In: *Jornal da Ciência*. [S.l.: s.n.], 26 de setembro de 2007.
- SIMÕES A. H. R. COSTA, e. M. T. C. A. A. S. Utilizando um classificador fuzzy para seleção visual de laranjas. *Workshop de Computação WORKCOMP, Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, SP*, p. 113117, 2001.

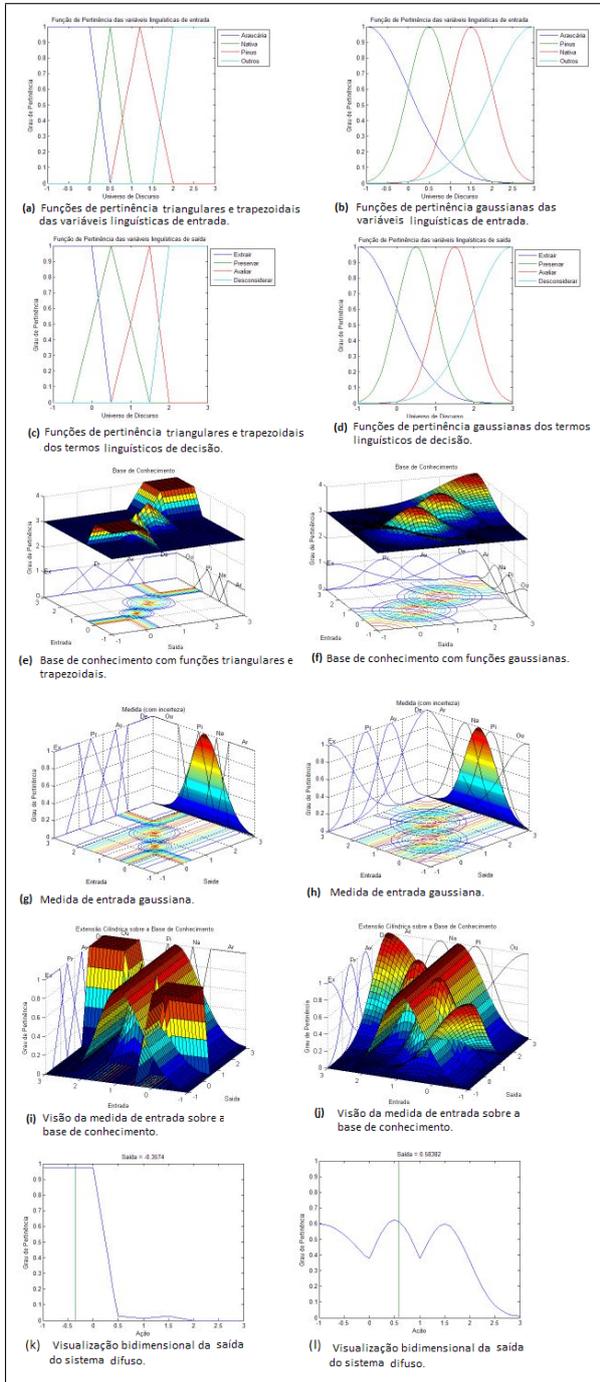


Figura 5: Características do sistema difuso do primeiro conjunto de simulação.

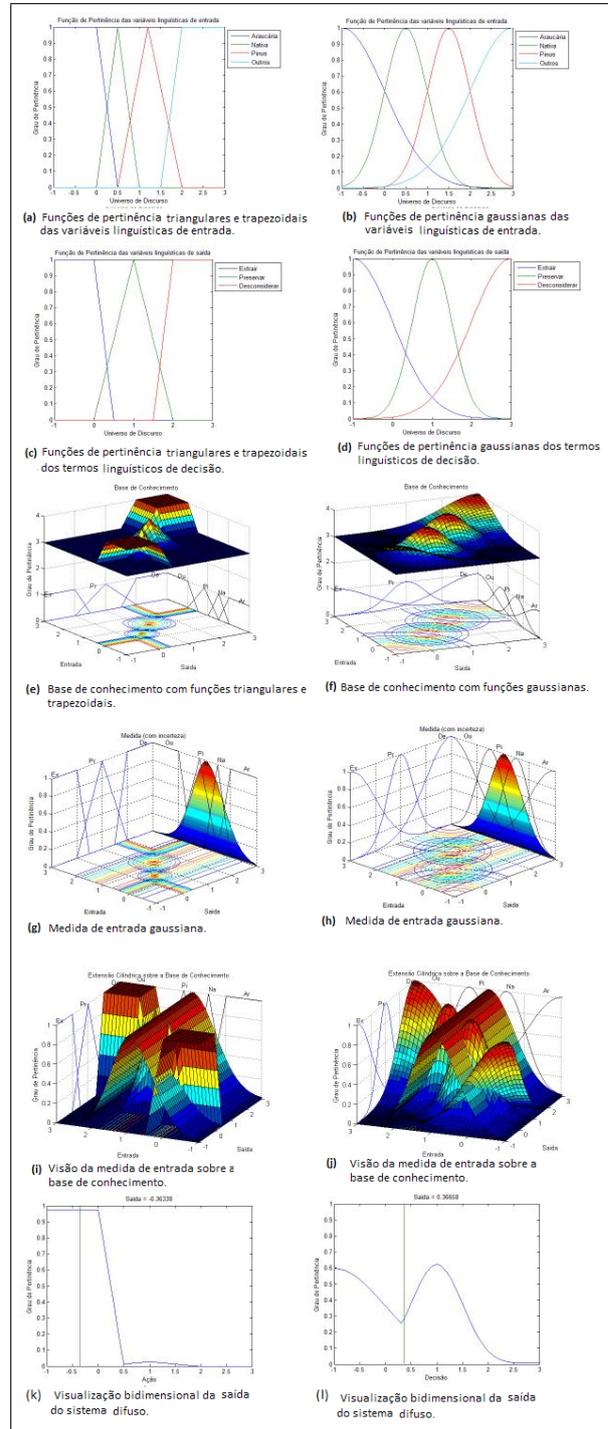


Figura 6: Características do sistema difuso do segundo conjunto de simulação.