

Boletim de Pesquisa **12** e Desenvolvimento *Junho, 2005*

ISSN 1677-9266

**Uma Abordagem Nebulosa para
Solução de Problemas de
Diagnóstico, Investigação e
Tratamento de Desordens**



República Federativa do Brasil

Luiz Inácio Lula da Silva

Presidente

Ministério da Agricultura, Pecuária e Abastecimento

Roberto Rodrigues

Ministro

Empresa Brasileira de Pesquisa Agropecuária - Embrapa

Conselho de Administração

Luis Carlos Guedes Pinto

Presidente

Silvio Crestana

Vice-Presidente

Alexandre Kalil Pires

Hélio Tollini

Ernesto Paterniani

Marcelo Barbosa Saintive

Membros

Diretoria-Executiva da Embrapa

Silvio Crestana

Diretor-Presidente

José Geraldo Eugênio de França

Kepler Euclides Filho

Tatiana Deane de Abreu Sá

Diretores-Executivos

Embrapa Informática Agropecuária

Eduardo Delgado Assad

Chefe-Geral

José Ruy Porto de Carvalho

Chefe-Adjunto de Administração

Kleber Xavier Sampaio de Souza

Chefe-Adjunto de Pesquisa e Desenvolvimento

João Camargo Neto

Supervisor da Área de Comunicação e Negócios



*Empresa Brasileira de Pesquisa Agropecuária
Embrapa Informática Agropecuária
Ministério da Agricultura, Pecuária e Abastecimento*

*ISSN 1677-9266
Junho, 2005*

Boletim de Pesquisa e Desenvolvimento 12

Uma Abordagem Nebulosa para Solução de Problemas de Diagnóstico, Investigação e Tratamento de Desordens

Silvia Maria Fonseca Silveira Massruhá
Marcelo Augusto Boechat Morandi
Sandra Sandri
Jacques Wainer

Campinas, SP
2005

Embrapa Informática Agropecuária
Área de Comunicação e Negócios (ACN)

Av. André Tosello, 209

Cidade Universitária "Zeferino Vaz" Barão Geraldo

Caixa Postal 6041

13083-970 – Campinas, SP

Telefone (19) 3789-5743 Fax (19) 3289-9594

URL: <http://www.cnptia.embrapa.br>

e-mail: sac@cnptia.embrapa.br

Comitê de Publicações

Carla Geovana Nascimento Macário

Ivanilde Dispatto

José Ruy Porto de Carvalho

Luciana Alvim Santos Romani (Presidente)

Marcia Izabel Fugisawa Souza

Marcos Lordello Chaim

Suzilei Almeida Carneiro

Suplentes

Carlos Alberto Alves Meira

Eduardo Delgado Assad

Maria Angelica de Andrade Leite

Maria Fernanda Moura

Maria Goretti Gurgel Praxedis

Normalização bibliográfica: *Maria Goretti Gurgel Praxedis*

Editoração eletrônica: *Área de Comunicação e Negócios (ACN)*

1ª. edição on-line - 2005

Todos os direitos reservados.

Uma abordagem nebulosa para solução de problemas de diagnóstico, investigação e tratamento de desordens / Sílvia Maria Fonseca Silveira Massruhá [et al.]. — Campinas: Embrapa Informática Agropecuária, 2005.

41 p. : il. (Boletim de Pesquisa e Desenvolvimento / Embrapa Informática Agropecuária; 12).

ISSN 1677-9266

1. Inferência abdução. 2. Lógica nebulosa. 3. Tomada de decisão. 4. Sistemas especialistas. 5. Doenças de plantas. I. Massruhá, Sílvia Maria Fonseca Silveira. II. Série.

CDD — 511.332 (21st ed.)

Sumário

Resumo.....	5
Abstract.....	6
Introdução	7
Material e Métodos.....	9
Resultados e Discussão.....	34
Conclusões.....	38
Referências Bibliográficas	40

Uma Abordagem Nebulosa para Solução de Problemas de Diagnóstico, Investigação e Tratamento de Desordens

Silvia Maria Fonseca Silveira Massruhá¹

Marcelo Augusto Boechat Morandi²

Sandra Sandri³

Jacques Wainer⁴

Resumo

Este trabalho tem por objetivo apresentar uma abordagem integrada para diagnóstico, investigação e tratamentos de desordens (doenças, falhas de computadores, etc.). Nesta nova abordagem, denominada Teoria das Coberturas Nebulosas (TCN), o conhecimento é basicamente modelado através de associações causais e a inferência é abdutiva. Conceitos de Parsimonious Covering Theory (PCT), lógica nebulosa e teoria de decisão são também integrados, de maneira a tratar os vários aspectos inerentes aos processos envolvidos em raciocínio clínico. Por exemplo, a possibilidade de diversas desordens estarem conjuntamente causando um conjunto de manifestações, a manipulação de informações temporais, a consideração de condições favoráveis ao desenvolvimento de uma desordem, a incapacidade do especialista em oferecer conhecimento generalizado desprovido de incerteza e/ou imprecisão, a manipulação de fatores cruciais na tomada de decisão nas tarefas de investigação e tratamento como o custo e o risco são alguns dos aspectos abordados neste trabalho. A validação do modelo teórico foi realizada em fitopatologia, abordando especificamente a diagnose, investigação e tratamento de doenças de milho. Entretanto, devido a sua generalidade, espera-se que os desenvolvimentos teóricos obtidos possam ser aplicados para resolver problemas de diagnóstico em outras áreas de conhecimento.

Termos para indexação: inferência abdutiva, lógica nebulosa, tomada de decisão, sistemas especialistas, representação do conhecimento, doenças de plantas.

¹ Doutora em Computação Aplicada, Pesquisadora da Embrapa Informática Agropecuária, Caixa Postal 6041, Barão Geraldo - 13083-970 - Campinas, SP. (e-mail: silvia@cnptia.embrapa.br)

² Doutor em Fitopatologia, Pesquisador da Embrapa Meio Ambiente, Caixa Postal 69 - 13820-000 - Jaguariúna, SP. (e-mail: mmorandi@cnpma.embrapa.br)

³ Doutora em Ciência da Computação, Pesquisadora do Institut d'Investigación en Intelligència Artificial - IIIA/CSIC - Belaterra Spain. (e-mail: sandri@iia.csic.es)

⁴ Doutor em Ciência da Computação, Pesquisador do Instituto de Computação da Unicamp, Caixa Postal 6176 - 13084-971 - Campinas, SP. (e-mail: wainer@ic.unicamp.br)

A Fuzzy Approach for Diagnosis, Investigation and Treatment Problem-Solving of Disorders

Abstract

This work presents an integrated framework for diagnosis, investigation and treatment of disorders (diseases, computer faults, etc.). In this new framework, called Fuzzy Covering Theory (FCT), knowledge is basically modeled through causal associations and inference is abductive. Concepts of Parsimonious Covering Theory (PCT), fuzzy sets logic and decision theory are also integrated, in order to address the various inherent aspects involved in clinical reasoning. For instance, the possibility of several disorders to conjunctively cause a series of manifestations, the manipulation of temporal information, the consideration of favorable conditions for the development of a disorder, the incapacity of an expert to yield generalized knowledge devoid of uncertainty/imprecision, the manipulation of crucial factors in decision making in investigation and treatment tasks like cost and risk are some of the aspects presented in this work. The validation of the theoretical model has been performed in phytopathology, specifically, at the diagnosis, investigation and treatment of the corn plants diseases. However, due to its generality, it is expected that the theoretical developments obtained in this work can successfully employed to solve diagnosis problems in other domains.

Index terms: abductive inference, fuzzy sets, decision-making, expert systems, knowledge representation, plants diseases.

Introdução

Nas últimas décadas, tem havido um grande crescimento na capacidade das pessoas de compreender o raciocínio humano e, em particular, o raciocínio clínico. As pesquisas realizadas nas disciplinas da ciência cognitiva, teoria de decisão e ciência da computação têm fornecido uma ampla visão do processo cognitivo que forma a base das decisões diagnósticas e terapêuticas que explicam um processo de raciocínio clínico. Segundo Réa-Neto (1998), o sucesso de um problema de raciocínio clínico depende de dois fatores: diagnóstico correto e tratamento efetivo. A solução para estes dois objetivos envolve duas grandes fases de tomada de decisão:

- a designação de um diagnóstico num nível de especificidade adequado para as considerações terapêuticas; e
- seleção de um tratamento que afete o problema de modo a resolvê-lo ou aliviá-lo.

Além dessas duas fases macros, existem outros estágios de tomada de decisão de menor ordem: selecionar perguntas a fazer; decidir que respostas são confiáveis; interpretar um sinal físico; selecionar um ou mais testes de laboratório; escolher uma ou mais das alternativas de tratamento.

Simplificadamente, o processo de solução dos problemas clínicos é constituído por dois grandes componentes que usualmente são considerados separadamente, embora eles provavelmente não possam ser separados na prática, no caso de especialistas humanos: uma base de conhecimento e um mecanismo de inferência, que é o método de aplicação do conhecimento utilizado pelo diagnosticador na busca da solução do problema. Os mecanismos de inferência utilizados na etapa de diagnóstico têm sido mais pesquisados na área de Inteligência Artificial (IA) enquanto os mecanismos de tomada de decisão têm sido estudados mais detalhadamente na área de Teoria de Decisão (TD).

Na década de 80 foram desenvolvidos vários sistemas em IA para automatizar a etapa de diagnóstico. Uma das características em comum destes sistemas é a de se comparar um modelo estabelecido para cada desordem com os dados do caso particular. Usualmente, estes sistemas são baseados em regras, onde as manifestações aparecem nas premissas e as causas nas conclusões (i.e. Efeitos → causas). Em conseqüência, o raciocínio adotado para a inferência nestes sistemas é do tipo dedutivo; a partir das regras (efeitos → causas) e fatos (efeitos), deduzem-se novas informações (causas). Como as causas dificilmente podem ser deduzidas com certeza a partir de um conjunto de manifestações, estes sistemas geralmente adotam algum modelo de representação de incerteza para permitir ao especialista exprimir sua confiança na regra.

Os sistemas baseados nesta abordagem tiveram um grande sucesso na época de seu surgimento, e geraram uma grande expectativa sobre a aplicação deste tipo de abordagem em qualquer área de conhecimento (Shortliffe, 1976). No entanto, muitos desenvolvedores de aplicações se frustraram na tentativa de modelar o conhecimento de seus especialistas no formato adotado por estes sistemas, e o interesse neste tipo de abordagem diminuiu, tendo como consequência levado a uma diminuição de interesse na área de IA em si, tanto no mundo acadêmico quanto nos outros setores.

Pode-se argumentar que o problema principal com este tipo de abordagem é que o conhecimento do tipo efeitos \rightarrow causas é contrário à maneira com que os fenômenos ocorrem na natureza (causas \rightarrow efeitos). Embora seja possível a criação de regras que inferem uma causa plausível para um conjunto de efeitos, os especialistas nem sempre conseguem ser precisos e raramente têm certeza absoluta sobre a informação que fornecem.

O conhecimento modelado através de regras do tipo causas \rightarrow efeitos é mais fácil de ser obtido, mesmo que algum tipo de incerteza/imprecisão permeie este conhecimento. Na década de 90, o conhecimento na forma causas \rightarrow efeitos passou a ser modelado, com o uso de raciocínio do tipo abdução; a partir das associações (causas \rightarrow efeitos) e fatos (efeitos), criam-se novas hipóteses (causas).

A Teoria das Coberturas Parcimoniosas - TCP (Peng & Reggia, 1990), representou uma primeira tentativa para formalizar o raciocínio causal abdução de diagnóstico. Embora a TCP original apresentasse como vantagem em relação à abordagem anterior, a capacidade de modelar regras do tipo causas \rightarrow efeitos e a ausência de uma modelagem de incerteza faziam com que a solução de um problema tendesse a ter muitas explicações alternativas. Uma versão posterior do sistema, permitiu o uso de informação probabilística na relação causal, possibilitando reduzir o tamanho das soluções do problema de diagnóstico, além de ordená-las, como apresentado em Peng & Reggia (1990).

No entanto, a modelagem da imperfeição da informação fornecida por especialistas não deveria necessariamente se limitar ao modelo de representação probabilista. Por exemplo, especialistas muitas vezes quantificam o quanto uma manifestação está associada a uma desordem de uma forma simbólica não-numérica ("muito comum", "moderado", "muito raro", etc.), termos estes que podem ser tratados como tal, no que se chama atualmente de "computing with words", ou traduzidos em números, usando seja probabilidade, seja outros modelos alternativos, como teoria de possibilidades, teoria de Dempster-Shafer ou fatores de certeza.

Desde o advento da TCP, vários autores têm investigado teorias da diagnose alternativas, ou extensões/modificações da TCP. Lucas (1996) permite

representar vários tipos de interações que não são possíveis na TCP original. Dubois & Prade (1995) propõem uma extensão possibilista à TCP para modelar as incertezas. Wainer & Rezende (1997) propõem uma extensão à TCP de modo que informações do tipo categórica e temporal possam ser incorporadas na base de conhecimento.

O trabalho de Wainer & Sandri (1998) mostra que é melhor representar a informação temporal como intervalos nebulosos. Entretanto, este trabalho se limita a verificar como uma desordem única cobre um conjunto de manifestações, ao invés de construir uma teoria de diagnóstico completa. O modelo proposto em Wainer & Sandri (1998) tem ainda algumas outras limitações como descrito em Massruhá (2003).

Os trabalhos citados acima têm apresentado soluções parciais na área de diagnóstico e não uma solução completa para o problema de raciocínio clínico. As soluções em IA para as tarefas de investigação e tratamentos ainda são muito tímidas (Tunez et al. 1998; Taboada et al. 1999). As tecnologias oferecidas em TD tais como matrizes de 'payoffs' (Savage, 1972), árvores de decisão (Raiffa, 1970), diagramas de influência entre outros (Henrion et al. 1992), por sua vez, propõem soluções para as tarefas de tomada de decisão nas áreas de investigação e tratamentos.

Cada vez mais nota-se a necessidade de integração das tecnologias desenvolvidas nas áreas de IA e TD, embora sejam baseadas em princípios diferentes, para suportar o raciocínio humano e a tomada de decisão pela formalização e automatização do conhecimento do especialista do domínio. Apesar de objetivos comuns, estes dois paradigmas têm divergências e diferenças fundamentais nos princípios e na prática. Conseqüentemente, a integração das tecnologias desenvolvidas em cada uma destas áreas não é trivial.

O objetivo deste trabalho é apresentar uma abordagem integrada para tomada de decisão no processo de raciocínio clínico que engloba diagnóstico, investigação e tratamentos de desordens, denominada Teoria das Coberturas Nebulosas (TCN), utilizando conceitos de inferência causal abduativa, lógica nebulosa e teoria de decisão. A TCN foi validada para diagnóstico, investigação e tratamentos de desordens de milho. Entretanto, espera-se que os desenvolvimentos teóricos obtidos neste trabalho possam ser aplicados para outros problemas de diagnóstico dinâmico. Um exemplo na área de diagnóstico e controle de falhas de satélite pode ser encontrado em Massruhá (2003).

Material e Métodos

A base de conhecimento de um sistema especialista para diagnóstico de doenças do milho, que foi desenvolvido na Embrapa Informática Agropecuária em parceria com a Embrapa Milho e Sorgo, foi utilizada como estudo de caso no presente trabalho (Embrapa, 2004).

A base de conhecimento original contém 41 doenças de milho com suas respectivas manifestações ou efeitos. No escopo deste trabalho foi necessário coletar informação adicional das 41 doenças de milho para representar a base de conhecimento. O conhecimento utilizado para complementar a base foi obtido através de entrevistas com fitopatologistas da Embrapa e médicos, além de literatura correspondente na área (Reis & Casa, 1996; Fernandes & Oliveira, 1997; Malcolm, 1980; Agrofitec, 2003). Adicionalmente a base de desordens, foi especificada uma base de conhecimento contemplando nove testes laboratoriais e uma base de conhecimento de tratamentos (corretivos) contemplando somente os fungicidas registrados pelo Ministério da Agricultura, Pecuária e Abastecimento. A especificação completa da base de conhecimento e os algoritmos que implementam a TCN estão apresentados em Massruhá (2003).

Na Fig. 1 está apresentada a estrutura geral da TCN. A TCN contempla a possibilidade de se ter um conjunto de desordens para explicar as manifestações de um caso particular, e não somente uma desordem, como proposto em Wainer & Sandri (1998). Além da classificação de hipóteses mais plausíveis para explicar um conjunto de manifestações, a TCN também classifica os exames prioritários para completar um diagnóstico e, dado um diagnóstico, classifica os tratamentos mais efetivos para ele.

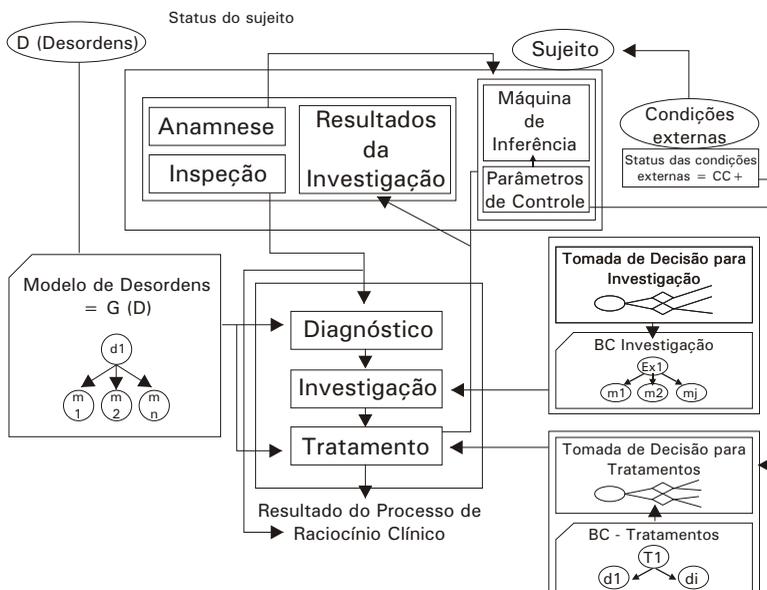


Fig. 1. Um ambiente integrado para diagnose e tratamento.

A arquitetura proposta para suportar o modelo apresentado acima é composta por três módulos principais conforme apresentado na Fig. 1. Em todos os três módulos da TCN, o conhecimento envolvido é do tipo causal e todo o raciocínio é

abduativo. Na tarefa de diagnóstico, as associações que modelam o conhecimento são do tipo desordem → manifestações, que, como visto anteriormente, são mais naturais que a associação reversa, o que facilita a interação com o especialista e que garante resultados mais confiáveis. Como o conhecimento sobre o caso é dado pelas manifestações presentes (ou ausentes) o raciocínio é naturalmente abduativo.

Na tarefa de investigação, as associações são do tipo exames → manifestações, pois cada exame é criado para verificar um conjunto de manifestações. Como o conhecimento sobre o caso é dado pelas manifestações cuja presença se pretende verificar, o raciocínio é também abduativo.

Finalmente, na tarefa de tratamento, as associações são do tipo tratamentos → desordens pois cada tratamento é criado visando ser útil para um conjunto de desordens (ou manifestações causadas por desordens). Como o conhecimento sobre o caso é dado pelas desordens presentes no caso, o raciocínio é mais uma vez abduativo.

A etapa de pré-diagnóstico, geralmente utilizada por diagnosticadores humanos, envolve dois aspectos principais: o levantamento de informações pertinentes ao problema em questão e a criação de um subconjunto de hipóteses iniciais que, aparentemente, são obtidas através da utilização de regras intuitivas do tipo manifestações → desordens. A criação de um subconjunto de hipóteses inicial pode ser extremamente útil para um diagnosticador humano, que assim não terá a necessidade de comparar os dados de um caso com os modelos de todas as desordens possíveis, ganhando desta forma tempo e evitando confusões. Esta heurística humana de focalização, no entanto, não é necessária em um sistema computacional no qual todo o conhecimento está modelado na forma de associações causais. Isto porque não existe restrição efetiva para um sistema varrer toda a base de conhecimento, comparando todos os modelos com os dados do caso. Na TCN, por exemplo, ao contrário do diagnosticador humano, o tempo dispendido nesta tarefa é pouco relevante e o desempenho do sistema não se degrada com o aumento de hipóteses. Por estas razões, a fase de pré-diagnóstico na TCN se resume ao levantamento de informações relevantes.

Conforme apresentado em Réa-Neto (1998), em complementação à decisão terapêutica deve-se ter um plano educacional do paciente e um procedimento de monitoramento dos tratamentos (efeitos do tratamento na progressão da desordem). Entretanto, a retroalimentação do processo de raciocínio clínico através da automatização do procedimento de monitoramento não está incluído no escopo deste trabalho.

A partir das idéias mencionadas, define-se formalmente o problema de raciocínio clínico. As definições apresentadas nesta seção constituem a base teórica para esta nova abordagem.

Definição 1. Um problema de raciocínio clínico P para diagnóstico, investigação e tratamentos é uma quadrúpla $P = \langle KB_d, Kb_o, KB_t, CA \rangle$ em que:

- KB_d é a base de conhecimento para representar informação correspondente às desordens e os efeitos que elas causam;
- Kb_o é a base de conhecimento para representar informação correspondente aos testes laboratoriais e às desordens ou manifestações que eles identificam;
- Kb_t é a base de conhecimento para representar informação correspondente aos tratamentos e às desordens que eles controlam;
- CA é a especificação de um caso particular (um paciente, uma cultura, um satélite, etc.).

Definição 2. Dada uma base de conhecimento $\Theta = \{KB_d, Kb_o, KB_t\}$ para o problema de raciocínio clínico P e um caso particular CA , $SOL(P) = \{SOL_d, SOL_o, SOL_t\}$ é uma solução abductiva para o caso particular CA se somente se $\Theta \cup SOL(P)$ cobre CA com adequação, coerência e parcimônia e $\Theta \cup SOL(P)$ é consistente.

O conhecimento associativo usado em problemas de diagnóstico, investigação e tratamentos é usualmente muito extenso e complexo. Portanto, neste trabalho o problema de raciocínio clínico é dividido em três subproblemas. Cada subproblema é representado por um ambiente abductivo que contém uma rede associativa com apenas duas entidades e uma relação binária entre elas. Na seqüência, as definições de cada base de conhecimento (KB_d, Kb_o, KB_t) bem como de cada solução $\{SOL_d, SOL_o, SOL_t\}$ serão detalhadas de modo a representar os problemas do mundo real nas áreas de diagnóstico, investigação e tratamentos, respectivamente.

Definição 3. A base de conhecimento KB_d é representada por uma sextupla $\langle D, M, R, G, CC, \rangle$ onde:

- D é o conjunto de desordens;
- M é o conjunto de manifestações;
- $R: D \times M \rightarrow [0, 1]$ é uma relação nebulosa que modela a associação gradual entre desordens e manifestações como apresentado na Tabela 1. Os tipos de causalidade existentes entre $\langle d, m_j \rangle$ são aqui divididas em cinco classes: d necessariamente causa m_j , d predominantemente causa m_j , d possivelmente causa m_j , d raramente causa m_j e d não causa m_j e estão aqui respectivamente associados aos pesos 1, 0.5, 0, -0.5, -1. Estes valores foram derivados a partir da interpretação dos tipos em termos de possibilidades e necessidades através da fórmula: $R(d, m_j) = \frac{\Pi(A) - \Pi(\sim A) - \text{Inferior}}{\text{Superior} - \text{Inferior}}$. Nas colunas 2 e 3 da Tabela 1 estão calculadas as medidas de possibilidades da associação $\langle d, m_j \rangle$ ocorrer ou não, respectivamente. As colunas 4 e 5 representam as medidas de necessidade para cada classe de associação e no caso do evento contrário, respectivamente. Na coluna 6 é calculada a função $p_{ij} = \Pi(A) - \Pi(\sim A) = N(A) - N(\sim A)$ que se refere às diferenças entre as medidas de possibilidades (colunas 2 e 3) e as medidas de

necessidade (colunas 4 e 5). Finalmente, na coluna 7 é apresentado o grau nebuloso associado a cada classe de $\langle d_i, m_j \rangle$ que corresponde à normalização de p_{ij} (Fig. 2).

- G é o grafo mínimo de eventos associado a cada desordem para representar a evolução temporal das manifestações de uma desordem. O grafo temporal de eventos de uma desordem $d_i \in D$, $G_i = (V, T)$, é um grafo direcionado acíclico e transitivo onde $V(d)$ são os nós do grafo que representam os eventos de início ou término de uma manifestação $m_j \in M$ rotulados por (m_j^b, m_j^e) e $T(d)$ é definido sobre o par de eventos (e_i, e_j) constituindo os arcos do grafo rotulados de (e_i, e_j) que representam os intervalos nebulosos mínimos entre quaisquer dos eventos que possam ocorrer na progressão de uma doença d_i (Fig. 3).
- CC é um conjunto de variáveis que modela condições de controle de uma desordem d_i representado pela tripla $CC = (CF, SEV, EP)$ (definição 7);
- é a escala de tempo.

Tabela 1. Associação causal nebulosa $\langle d_i, m_j \rangle$.

$C = \langle d_i, m_j \rangle$	(A)	(-A)	N(A)	N(-A)	p_{ij}	$R(d_i, m_j) = Norm(p_{ij})$
" d_i necessariamente causa m_j "	1.0	0	1.0	0	1.0	$1.0 + - 1.0 / 2 = 1.0$
" d_i predominantemente causa m_j "	1.0	0.5	0.5	0	0.5	$0.5 + - 1.0 / 2 = 0.5$
" d_i possivelmente causa m_j "	1.0	1.0	0	0	0	$0 + - 1.0 / 2 = 0.25$
" d_i raramente causa m_j "	0.5	1.0	0	1.0	-0.5	$-0.5 + - 1.0 = 0.25$
" d_i não causa m_j "	0	1.0	0	1.0	-1.0	$-1.0 + - 1.0 = 0$

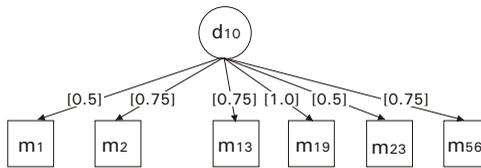


Fig. 2. Associação gradual $R = \langle d_{10}, m_j \rangle$.

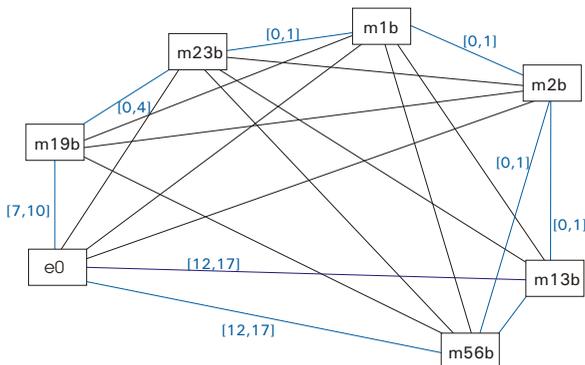


Fig. 3. Grafo mínimo de eventos de d_{10} .

Conforme descrito na definição 3, além da associação causal entre desordens/manifestações e a evolução temporal das manifestações para uma determinada desordem, outra propriedade característica de um ambiente de diagnóstico são as condições de controle que interferem na evolução de uma desordem. Por exemplo, as condições favoráveis de temperatura e umidade, a intensidade ou severidade de uma desordem e a época ou idade que favorece a evolução da desordem. No escopo da TCN, este tipo de informação também é representada através de intervalos nebulosos como descrito na definição 7. Vários autores tem proposto modelos e escalas para medir as variáveis de intensidade ou severidade da desordem no momento do diagnóstico. A escala diagramática a ser utilizada nos exemplos de doenças de milho está representada na Tabela 4 e foi adaptada de Morandi & Menezes (2002). Na Tabela 5 está apresentado o intervalo nebuloso assumido para os estágios de desenvolvimento da cultura. As Tabelas 6 e 7 exemplificam os intervalos assumidos para Temperatura e Umidade no domínio agrícola $CF = \langle TEMP, UMID \rangle$, respectivamente.

Antes de definir as condições de controle $CC = (CF, SEV, EP)$, é importante definir um intervalo nebuloso trapezoidal. Um intervalo nebuloso trapezoidal bem como as operações em conjuntos nebulosos (soma e subtração) que serão utilizadas neste trabalho estão definidas a seguir.

Definição 4. Um intervalo nebuloso trapezoidal $\langle a_1, a_2, a_3, a_4 \rangle$, é tal que $\alpha_A(x) = 1$, $x \in [a_2, a_3]$, $\alpha_A(x) = 0$, $x \notin [a_1, a_4]$, $\alpha_A(x) = \frac{x-a_1}{a_2-a_1}$, $x \in [a_1, a_2]$, e $\alpha_A(x) = \frac{a_4-x}{a_4-a_3}$, $x \in [a_3, a_4]$.

Definição 5. Em um intervalo trapezoidal $A = \langle a_1, a_2, a_3, a_4 \rangle$ o intervalo $[a_2, a_3]$, onde $\alpha_A(x) = 1$, é chamado de núcleo (core) de A. O intervalo $[a_1, a_4]$, onde $\alpha_A(x) = > 0$, é chamado de suporte de A. Um intervalo $\langle a, a, b, b \rangle$ é dito ser bem definido e é representado por $\langle a, b \rangle$.

Definição 6. Seja A e B intervalos nebulosos trapezoidais. As operações de soma e subtração correspondem a: $A \oplus B = \langle a_1 + b_1, a_2 + b_2, a_3 + b_3, a_4 + b_4 \rangle$ e $A \ominus B = \langle a_1 - b_4, a_2 - b_3, a_3 - b_2, a_4 - b_1 \rangle$.

Definição 7. As condições de controle CC de uma desordem d_i é representada pela tripla (CF, SEV, EP) onde:

- o par CF corresponde aos intervalos nebulosos trapezoidais que representam as condições favoráveis à evolução de uma desordem d_i ;
- SEV corresponde a um grau nebuloso trapezoidal de intensidade ou severidade de uma desordem d_i (Tabela 4);
- EP corresponde a um intervalo nebuloso que representa a fase de desenvolvimento ou idade de um determinado paciente ou planta que favorece a evolução de uma determinada desordem (Tabela 5).

Para um problema de diagnóstico representado por KB_d , é também conveniente e útil definir os conjuntos ou funções baseadas na relação C:

Definição 8. Para todo $d_i \in D$ e $m_j \in M$ em uma base de conhecimento KB_d ,

- efeitos (d_i) = $\{m_j \mid \langle d_i, m_j \rangle \in C\}$, o conjunto dos elementos diretamente causados por d_i ;
- causas (m_j) = $\{d_i \mid \langle d_i, m_j \rangle \in C\}$, o conjunto dos elementos que podem diretamente causar m_j .

Os conjuntos definidos acima podem facilmente ser generalizados de desordens e manifestações individualmente para conjuntos de desordens e manifestações conforme apresentado a seguir.

Definição 9. Para todo $D_L \subseteq D$ e $M_J \subseteq M$ em uma base de conhecimento KB_d ,

- efeitos (D_L) = $\bigcup_{d_i \in D_L} \text{efeitos}(d_i)$, e
- causas (M_J) = $\bigcup_{m_j \in M_J} \text{causas}(m_j)$.

Assim, os efeitos de um conjunto de desordens são apenas a união dos efeitos individuais de cada desordem do conjunto. Por exemplo, no problema de diagnóstico apresentado na Fig. 2 tem-se:

efeitos (d_{10}) = $\{m_1, m_2, m_{13}, m_{19}, m_{23}, m_{56}\}$,

causas (m_1) = $\{d_1, d_2, d_3, d_{10}\}$.

Para exemplificar a representação do conhecimento sobre um problema de diagnóstico no domínio de doenças de plantas utilizando as definições apresentadas, as principais características de uma doença, denominada Mancha por *Cercospora* (d_{10}) estão resumidas na Tabela 2. Em seguida, na Tabela 3 está apresentada a sextupla da base de conhecimento $KB_d = \langle D, M, R, G, CC \rangle$ correspondente a desordem d_{10} que ilustra como estas características podem ser representadas em KB_d .

A primeira coluna da Tabela 3, refere-se a escala de tempo representada na Tabela 5. A segunda coluna D refere-se as desordens que compõem a base de conhecimento (neste exemplo d_{10}). Na coluna M está representado o conjunto de manifestações causadas por d_{10} : (efeitos(d_{10}) = $\{m_1, m_2, m_3, m_{13}, m_{19}, m_{23}, m_{56}\}$). Na coluna R está representada a associação gradual entre desordens e manifestações como apresentado na Fig. 2. Na coluna G está referenciado o grafo mínimo de eventos associado a desordem d_{10} (Fig. 3). A última coluna, CC, representada pela tripla $CC = (CF, SEV, EP)$ onde o par $CF = (TEMP, UMID)$ corresponde aos intervalos nebulosos trapezoidais que representam as condições favoráveis de temperatura e umidade que favorecem a evolução da desordem d_{10} (Tabela 3). A variável SEV corresponde a um intervalo nebuloso trapezoidal de intensidade ou severidade em que d_{10} pode aparecer (Tabela 4) e a variável EP, corresponde a um intervalo nebuloso que representa a fase de desenvolvimento ou

idade de um determinado paciente ou planta que favorece a evolução de d_{10} (Tabela 5).

Tabela 2. Principais características da Cercosporiose.

<i>Mancha por Cercospora(d_{10})</i>	
Sintomas	A reação de susceptibilidade é caracterizada por lesões retangulares, limitadas pelas nervuras, inicialmente de cor palha passando a cinza. Podem ocorrer na bainha, colmo e palhas das espigas. A Cercosporiose, sob condições favoráveis, pode causar seca prematura das plantas e geralmente causam tombamento. Essa doença pode ser encontrada em qualquer fase do desenvolvimento das plantas de milho, inicialmente nas folhas baixas.
Condições favoráveis	Temperatura entre 23 e 35°C, e água livre na superfície das folhas.
Medidas de controle	Aplicação de fungicidas, utilização de cultivares resistentes; rotação de cultura; aração e gradagem.

Tabela 3. Ênupla correspondente a representação da desordem Cercospora d_{10} em Kb_d .

D	M	$R =$ $\langle d_{10}, m_j \rangle$	$G(V, T)$	$CC = (CF, SEV, EP)$
$\langle 0,22 \rangle$ semanas	m_1 : folhas se coalescem	0.5	Grafo de eventos (Fig 3)	$CF = (TEMP = \langle 25,30,35,40 \rangle,$ $UMID = \langle 85,90,95,100 \rangle)$
	m_2 : seca em grandes áreas foliares	0.75		$SEV = \langle 1,10 \rangle$ (Tabela 4)
	m_{13} : lesões necróticas palha	0.75		$EP = \langle 0.22 \rangle$ (Tabela 5)
	m_{19} : lesões necróticas palha	1.0		
	m_{23} : lesões necróticas cinzas	1.0		
	m_{26} : geralmente tombam	0.75		

Tabela 4. Níveis de severidade da cultura do milho.

Nível de severidade	Descrição do nível	Grau nebuloso
S_1	Sem lesões (antes do aparecimento dos sintomas)	-
S_2	Lesões esparsas na planta, restritas ao terço inferior	$\langle 1,2,3,4 \rangle$
S_3	Até 50% das folhas com lesões; severas nos 25% das folhas inferiores	$\langle 3,4,5,6 \rangle$
S_4	Até 75% das folhas com lesões; severas nos 50% das folhas inferiores	$\langle 5,6,7,8 \rangle$
S_5	100% das folhas com lesões; lesões severas nos 75% das folhas inferiores	$\langle 7,8,9,10 \rangle$
S_6	Planta morta	-

Tabela 5. Etapas de desenvolvimento da cultura de milho.

<i>Estágios</i>	<i>Descrição</i>	<i>Intervalos (em dias)</i>	<i>Intervalo nebuloso (em semanas)</i>
0	Germinação	0 a 10	< 0, 1, 1, 2 >
1	Crescimento vegetativo	10 a 55	< 2, 4, 6, 8 >
2	Pendoamento	55 a 70	< 8, 9, 9, 10 >
3	Florescimento	70 a 80	< 9, 10, 11, 12 >
4	Frutificação	80 a 120	< 12, 13, 16, 17 >
5	Maturação	120 a 150	< 17, 18, 21, 22 >

Para complementar a formulação do problema de diagnóstico, necessita-se de um caso particular conforme descrito na definição 1. Utilizando a terminologia da TCP, M^+ é utilizado como subconjunto de M para referenciar as manifestações presentes que correspondem as observações do caso e M^- refere-se também a um subconjunto de M que corresponde as manifestações ausentes no caso. A informação sobre um caso particular deve contemplar observações adicionais, além das manifestações presentes e ausentes, tais como, em que época estas manifestações ou sintomas ocorreram, quando elas começaram e como evoluíram, a severidade e intensidade de cada uma bem como condições ambientais em que elas ocorreram.

Tabela 6. Graus de temperatura.

<i>Grau</i>	<i>Temperatura (T)</i>	<i>Intervalo nebuloso</i>
Alta	$T > 25^\circ\text{C}$	< 25, 30, 35, 40 >
Média	$15^\circ\text{C} < T < 25^\circ\text{C}$	< 15, 20, 25, 30 >
Baixa	$T < 15^\circ\text{C}$	< 0, 10, 15, 20 >

Tabela 7. Graus de umidade.

<i>Grau</i>	<i>Umidade (U)</i>	<i>Intervalo nebuloso</i>
Alta	$U > 85\%$	< 85, 90, 95, 100 >
Média	$70\% < U < 80\%$	< 70, 75, 80, 85 >
Baixa	$U < 70\%$	< 0, 20, 40, 70 >

Normalmente, a informação sobre o caso particular é coletada através de um processo denominado anamnese em que o especialista do domínio (médico, fitopatologista ou engenheiro) coleta as informações do próprio paciente, produtor ou computador. Formalmente, a informação sobre um dado caso pode ser definida como a seguir.

Definição 10. A informação sobre um caso particular é modelada por uma quintupla $CA = \langle M^+, M^-, EV^+, TIME^+, CC^+ \rangle$ onde:

- M^+ é o conjunto de manifestações presentes conhecidas no caso;
- M^- é o conjunto de manifestações ausentes conhecidas no caso;
- EV^+ é o conjunto de eventos de início (m_i^+) e fim (m_f^+) de cada manifestação em M^+ ;

- $TIME^+$ é uma função que associa para cada evento $e_i \in EV^+$ um intervalo nebuloso que representa os momentos possíveis no qual o evento ocorreu;
- $CC^+ = (CF^+, SEV^+, EP^+)$ são as condições externas em que ocorreram os sintomas, onde no domínio agrícola CF^+ é uma função que associa as condições de temperatura e umidade ($TEMP^+$, $UMID^+$) no momento do diagnóstico, SEV^+ e EP^+ são as funções que associam a severidade de cada $m_j \in M^+$ e a fase em que elas ocorreram, respectivamente.

Para ilustrar a definição 10, suponha um caso hipotético em que um produtor de milho procura um fitopatologista na décima-oitava semana de plantio, pois sua lavoura apresentou algumas manifestações. Após uma entrevista com o produtor, o fitopatologista coletou algumas observações adicionais: por volta da oitava à nona semana começaram aparecer os sintomas; por volta da nona à décima semana apareceram nas folhas, algumas lesões necróticas palha (m_{19} da Tabela 3); 50% das folhas apresentam lesões e 25% das folhas apresentam em maior intensidade (s_3 da Tabela 4); por volta da décima-primeira e décima-segunda semana aproximadamente após a germinação as folhas começaram a coalescer (m_1) e algumas tornaram-se secas prematuramente e por volta da décima-terceira semana muitas tombaram (m_{56} da Tabela 3); por volta da décima-sétima e décima-oitava semana tornaram-se secas prematuramente (m_{13} da Tabela 3); as condições climáticas da região oscilam com uma temperatura entre 23 e 25°C e com uma alta umidade relativa do ar e foi notado que as lesões não estavam circundadas por halo amarelado (corresponde a m_{20} na Kb_d).

Conforme apresentado na definição 10, este caso particular pode ser representado pela quintupla $CA = \langle M^+, M^-, EV^+, TIME^+, CC^+ \rangle$ onde,
 $M^+ = \{m_1, m_{13}, m_{19}, m_{56}\}$, $M^- = \{m_{20}\}$, $EV^+ = \{m_1^b, m_{13}^b, m_{19}^b, m_{56}^b\}$,
 $TIME^+(m_1^b) = \langle 10, 11, 12, 14 \rangle$, $TIME^+(m_{13}^b) = \langle 16, 17, 18, 19 \rangle$,
 $TIME^+(m_{56}^b) = \langle 12, 13, 14, 15 \rangle$ e $TIME^+(m_{19}^b) = \langle 8, 9, 10, 11 \rangle$,
 $CC^+ = \{CF^+, SEV^+, EP^+\}$ onde
 $EP^+ = \langle 8, 9 \rangle$, $SEV^+ = \langle 3, 4, 5, 6 \rangle$ e
 $CF^+ = \{TEMP^+ = \langle 22, 23, 25, 26 \rangle, UMID^+ = \langle 80, 85, 90, 95 \rangle\}$.

Uma vez caracterizado o problema de diagnóstico ($P = \langle Kb_d, CA \rangle$), caracteriza-se agora sua solução, denominado $SOL_d(P)$. Para isto, além da noção de "cobertura", utiliza-se outros índices de consistência e coberturas nebulosas que serão descritos a seguir.

As explicações ou hipóteses mais plausíveis $SOL_d \subseteq D$ (desordens ou falhas) devem ser inferidas abduativamente a partir da consistência entre a informação sobre o caso particular CA (sintomas ou resultados de testes) coletada através da anamnese e a base de conhecimento Kb_d . Para tal, é utilizada a noção de coberturas irredundantes da TCP. Uma cobertura C para um caso particular CA é dita ser irredundante se nenhum de seus subconjuntos próprios for também uma

cobertura de M^+ ; caso contrário a cobertura é dita ser redundante. O critério de parcimônia irredundante garante a noção de minimalidade e simplicidade explicitada anteriormente. Outros critérios de parcimônia podem ser consultados em Peng & Reggia (1990).

No escopo da TCN, antes de aplicar o critério de parcimônia de irredundância, é necessário verificar a consistência temporal, categórica e das condições de controle do caso particular em relação ao modelo de desordens. Para isto, são utilizados os índices de consistência temporal, categórica e de intensidade propostos em Wainer & Sandri (1998). Segundo Wainer & Sandri (1998), a consistência temporal entre o caso e o modelo é calculada pela comparação do tempo transcorrido entre os eventos do caso (os eventos em EV^+) e os intervalos nebulosos correspondentes no modelo. Primeiramente, deve ser calculada a distância temporal entre pares de todos os eventos de EV^+ como descrito na definição 11.

Definição 11. Dado que e_i e $e_j \in EV^+$ de um caso particular CA, calcula-se a distância temporal nebulosa entre as ocorrências reais dos eventos e_i e e_j através da fórmula $DIST^+(e_i, e_j) = TIME^+(e_j) \ominus TIME^+(e_i)$.

Na seqüência, para comparar como estes dois eventos (e_i e e_j) se encaixam no modelo de uma desordem particular d_i deve-se comparar a altura da intersecção de $DIST^+(e_i, e_j)$ com (e_i, e_j) . Formalmente, a consistência temporal entre uma caso CA e uma desordem d_i é definido como descrito na definição 12.

Definição 12. Um caso particular CA é consistente temporalmente com o modelo de uma desordem d_i se seu grau de consistência temporal for maior que zero, isto é, se $(d_i) = \min_{e_i, e_j \in EV^+ \cap V(d_i)} [h(DIST^+(e_i, e_j) \cap (e_i, e_j))] > 0$.

Para exemplificar a consistência temporal, considere o conjunto de manifestações do caso $M^+ = \{m_{13}, m_{19}\}$, $EV^+ = \{m_{13}^b, m_{19}^b\}$, $TIME^+(m_{13}^b) = \langle 16, 17, 18, 19 \rangle$ e $TIME^+(m_{19}^b) = \langle 8, 9, 10, 11 \rangle$. Portanto, tem-se $DIST^+(m_{13}^b, m_{19}^b) = \langle 5, 7, 9, 11 \rangle$. A partir do grafo mínimo (Fig. 3), tem-se que $(m_{13}^b, m_{19}^b) = \langle 2, 10 \rangle$ e conseqüentemente tem-se $\alpha(d_{10}) = h(\langle 5, 7, 9, 11 \rangle \cap \langle 2, 10 \rangle) = 1.0$. Assim, d_{10} poderia ser considerada uma explicação plausível para o conjunto de manifestações M^+ .

Adicionalmente, conforme apresentado em Wainer & Sandri (1998), a consistência categórica está intimamente ligada à consistência temporal, pois, um caso é categoricamente inconsistente com um modelo caso uma manifestação necessária não tenha ocorrido e já não há mais tempo suficiente para que ela ocorra. Uma manifestação m_j é dita ter tempo suficiente para ter ocorrido em d_i se: existe um evento e_j que deveria ocorrer após m_j e ele já ocorreu ou existe um evento e_i que era previsto ocorrer antes de m_i , ele ocorreu e o tempo

previsto para ocorrer m_j após e_i já ultrapassou. Assim, o índice de consistência temporal e categórica $\alpha_\alpha(d_i)$ no escopo da TCN pode ser definido como descrito na definição 13.

Definição 13. Um caso particular CA é consistente temporal e categoricamente com o modelo de uma desordem d_i se:

- tiver a seguinte inicialização, $m_j \in M^+ \cap R(d_i, m_j) = 1$, $TIME^+(m_j^b) = I_{afternow} = I_{\geq 0}$, tal que $x \in \dots$, se $x \geq 0$, $\alpha_A(x) = 1$ caso contrário $\alpha_A(x) = 0$;
- seu grau de consistência temporal e categórica for maior que zero, isto é, se $\alpha_\alpha(d_i) = \min_{e_i, e_j \in EV^+ \cap V(d_i)} [h(DIST^+(e_i, e_j) \cap \dots(e_i, e_j))] > 0$.

Para exemplificar a consistência categórica no escopo da TCN, será considerado o caso hipotético em que o momento de diagnóstico é igual a 18 (semanas) e que temos $M^- = m_{23}$.

Se forem considerados M^+ sem considerar M^- , tem-se que o caso é compatível com a doença d_{10} conforme apresentado anteriormente. Se for considerada a ausência da manifestação m_{23} onde $R(d_{10}, m_{23}) = 1.0$, com $TIME^+(m_{23}^b) = I_{afternow} = \langle 18, \infty \rangle$, o caso já não é compatível com o modelo de d_{10} , conforme apresentado a seguir:

$$\alpha(d_{10}) = \min \begin{cases} h(DIST^+(m_{13}^b, m_{19}^b) \cap \pi_1(m_{13}^b, m_{19}^b)), \\ h(DIST^+(m_{23}^b, m_{13}^b) \cap \pi_1(m_{23}^b, m_{13}^b)), \\ h(DIST^+(m_{23}^b, m_{19}^b) \cap \pi_1(m_{23}^b, m_{19}^b)) \end{cases}$$

$$\alpha(d_{10}) = \min \begin{cases} h(\langle 5, 7, 9, 11 \rangle \cap \langle 2, 10 \rangle), \\ h(\langle -\infty, 1 \rangle \cap \langle -2, 10 \rangle), \\ h(\langle -\infty, -7 \rangle \cap \langle 0, 4 \rangle), \end{cases}$$

$$\alpha(d_{10}) = \min(1, 1, 0) = 0.$$

No escopo da TCN, uma explicação para o diagnóstico assumida é uma desordem que tem consistência temporal e categórica com todos os sintomas e explica todos os sintomas presentes no caso com certo grau de verossimilhança, como definido a seguir.

Definição 14. Um conjunto $SOL_d \subseteq D$ é uma explicação plausível para um problema $P = \langle KB_d, CA \rangle$ onde $CA = \langle M^+, M^-, EV^+, TIME^+, CC^+ \rangle$ se

- SOL_d cobre M^+ , e
- SOL_d satisfaz algum critério de parcimônia, e
- $d_i \in SOL_d$, $\alpha(d_i) > 0$, isto é, d_i é consistente temporalmente e categoricamente, e
- $D_i \subseteq SOL_d$, $\alpha(D_i) = \min(\alpha(d_i) \mid \{d_i \in D\})$, isto é, o grau de certeza de uma hipótese D_i é igual ao menor grau de consistência de uma desordem $d_i \in D_i$ tal que $D_i \in SOL_d$.

A melhor explicação para um caso particular CA é uma cobertura D_i com maior grau de certeza, isto é, $D_i \in SOL_d$ existe uma classificação onde as hipóteses com os mais altos graus de certeza constituem as hipóteses mais plausíveis. O grau de certeza das hipóteses mais plausíveis é calculado pelo menor grau de consistência temporal e categórica das desordens que a compõem, como já foi definido. Entretanto, quando existir duas desordens com mesmo grau de certeza ($\alpha(D_i)$), é considerada a hipótese mais plausível é a hipótese com maior grau de compatibilidade com as condições de controle ((D_i)) como definido a seguir.

Definição 15. Dado que $(D_i) = \min(\{d_i\} | \{d_i \in D_i\})$, uma cobertura $D_x \in SOL_d$ é uma explicação mais plausível para um caso particular CA se $D_i \subseteq SOL_d | D_i \ D_x$
 $(D_i) = (D_x)$ e $(D_x) > (D_i)$.

No escopo da TCN, quando uma hipótese D_i não atinge um certo grau de verossimilhança (i.e., $(D_i) < \Delta$) pode ser assumido que os efeitos causados por cada d_i tal que $d_i \in D_i$ devem ser melhor investigados (i.e, através de exames complementares ou testes laboratoriais) visando um refinamento das hipóteses.

Exemplificando as definições 14 e 15, ao aplicar o modelo de consistência para o caso hipotético CA apresentado tem-se que $SOL_d = \{\{d_{10}\}, \{d_{18}, d_2\}\}$ tal que $(\{d_{10}\}) = .75$ e $(\{d_{18}, d_2\}) = .33$ ($(\{d_{18}\}) = .33$, $(\{d_2\}) = .67$) é uma explicação plausível. Dado que o fator de certeza da hipótese $\{d_{10}\}$ é igual a 0.75 e o grau de certeza da outra hipótese é igual a 0.33, então a explicação mais plausível para este caso é $\{d_{10}\}$.

Observe que na segunda hipótese de SOL_d ($\{d_{18}, d_2\}$), a vírgula representa um (*and*), portanto, a hipótese $\{d_{18}, d_2\}$ representa d_{18} e d_2 ocorrem simultaneamente. Como d_{18} é uma desordem fúngica e d_2 é uma doença bacteriana, é muito baixa a possibilidade das duas desordens estarem ocorrendo simultaneamente. Entretanto, somente através de testes laboratoriais as hipóteses poderiam ser confirmadas. O ambiente abduativo para investigação será detalhado a seguir.

O ambiente abduativo para investigação é similar ao ambiente abduativo definido para diagnóstico no escopo da TCN. Durante o processo de diagnóstico, é importante selecionar quais as manifestações prioritárias para completar o diagnóstico e, conseqüentemente, quais os exames a serem solicitados para confirmar a existência destas manifestações. Este ciclo diagnóstico/investigação pode ser repetido até que um diagnóstico final seja encontrado. A próxima definição formaliza a base de conhecimento para exames em um dado momento no tempo.

Definição 16. A base de conhecimento para investigação é representada pela quintupla $KB_e = \langle E, D, M, I, R \rangle$, onde:

- E é o conjunto de exames ou testes laboratoriais possíveis e_i para verificar a existência de manifestações em um determinado domínio de aplicação;
- D é o conjunto de desordens;
- M é o conjunto de manifestações m_i ou efeitos observados (sintomas, falhas, etc.) que podem ocorrer quando uma ou mais desordens estiverem presentes;
- $I: E \times M \rightarrow \{0, 1\}$ é uma relação binária que modela a associação entre exames e manifestações; se $(e_i, m_j) \in I$ então e_i é um exame apropriado para a detecção da existência de m_j ;
- $R: D \times M \rightarrow [0, 1]$ é uma relação nebulosa que modela a associação gradual entre desordens e manifestações como apresentado na Tabela 1.

Para um problema de investigação representado por KB_e , é conveniente e útil definir os seguintes conjuntos obtidos através da relação I :

Definição 17. Para todo $e_i \in E$ e $m_j \in M$ em uma base de conhecimento KB_e , temos

- $resultados(e_i) = \{m_j \mid \langle e_i, m_j \rangle \in I\}$ é o conjunto das manifestações diretamente identificados pelo exame e_i ;
- $exames(m_j) = \{e_i \mid \langle e_i, m_j \rangle \in I\}$ é o conjunto dos exames que podem diretamente identificar a manifestação m_j .

Os conjuntos definidos acima podem facilmente ser generalizados de resultados e exames individuais para conjuntos de resultados e exames similar a definição 9.

Utilizando o mesmo exemplo em doenças de milho, um subconjunto da base de conhecimento de testes laboratoriais para identificação de doenças de milho que contém 9 testes laboratoriais são listados na Tabela 8.

Tabela 8. Exemplo de testes laboratoriais.

Referência	Exames	Tipos de desordens
e_1	Análise macroscópica	Fúngicas
e_2	Microscopia ótica	Fúngicas, bacterianas
e_3	Isolamento em cultura pura	Fúngicas
e_4	Testes bioquímicos	Bacterianas
e_5	Análise perfil ácidos graxos	Bacterianas
e_6	Análise de ribossomo	Bacterianas
e_7	Testes sorológicos	Bacterianas, viroses, enfezamentos e fúngicas
e_8	Análise de DNA	Viroses, enfezamentos
e_9	Microscopia eletrônica	Viroses, enfezamentos

Na Tabela 9 está apresentado um exemplo da 6-tupla da base de conhecimento $Kb_e = \langle E, I, D, M, R \rangle$ correspondentes aos testes laboratoriais que podem identificar d_{10} , exemplificando como os exames ou testes laboratoriais para desordens de milho podem ser representados no escopo da TCN.

Tabela 9. Tupla correspondente a representação dos testes laboratoriais que identificam d_{10} em Kb_a .

	<i>E</i>	<i>I</i>	<i>D</i>	<i>M</i>	$R = \langle d_{10}, m_j \rangle$
$\langle 0,22 \rangle$	e_1	$\langle e_1, d_{10} \rangle$	d_{10}	m_1 : folhas se coalescem	0.5
semanas	e_2	$\langle e_2, d_{10} \rangle$		m_2 : seca em grandes areas foliares	0.75
	e_3	$\langle e_3, d_{10} \rangle$		m_{13} : seca prematura das plantas	0.75
	e_7	$\langle e_7, d_{10} \rangle$		m_{19} : lesões necróticas palha	1.0
	e_8	$\langle e_8, d_{10} \rangle$		m_{23} : lesões necróticas cinzas	1.0
				m_{56} : geralmente tombam	0.75

A primeira coluna da Tabela 9, θ refere-se a escala de tempo representada na Tabela 5. A segunda coluna E refere-se aos testes laboratoriais que compõem a base de conhecimento (Tabela 8). Na coluna I está representada a associação entre os testes laboratoriais e as desordens. Na coluna D está representado as desordens em que aparecem as manifestações (neste exemplo somente d_{10}). Na coluna M está representado o conjunto de manifestações causadas por d_{10} : $\text{efeitos}(d_{10}) = \{m_1, m_2, m_{13}, m_{19}, m_{23}, m_{56}\}$. Na coluna R está representada a associação gradual entre desordens e manifestações como apresentado na Fig. 2.

Para completar a formulação do problema de investigação é necessário formalizar os casos particulares. No escopo de investigação, a informação sobre um caso particular deve contemplar apenas observações sobre manifestações presentes e ausentes.

Definição 18. A informação sobre um caso particular na etapa de investigação é modelada por uma tripla $CA = \langle D^+, M^+, M^- \rangle$ onde:

- $D^+ \subseteq \wp(D)$ é o conjunto de hipóteses para o caso;
- M^+ é o conjunto de manifestações certamente presentes no caso;
- M^- é o conjunto de manifestações certamente ausentes no caso.

O conjunto D^+ pode ter sido derivado a partir da aplicação do módulo de diagnóstico, e neste caso, portanto, $D^+ = \text{SOL}_d$. O conjunto de desordens presentes nas coberturas em D^+ é dado por $D^+ = \bigcup_{D_k \in D^+} D_k$. Por exemplo, para $D^+ = \{\{d_1\}, \{d_2, d_3\}\}$, tem-se $D^+ = \{d_1, d_2, d_3\}$. O conjunto de manifestações cuja investigação é pertinente ao caso apresentado é dado por $M^+ = \text{efeitos}(D^+) - (M^+ \cup M^-)$. Por exemplo, para $M^+ \cup M^- = \{m_3\}$, $D_j^+ = \{\{d_1\}, \{d_2, d_3\}\}$, $\text{efeitos}(d_1) = \{m_1, m_3\}$, $\text{efeitos}(d_2) = \{m_2, m_3\}$ e $\text{efeitos}(d_3) = \{m_4\}$ tem-se $M^+ = \{m_1, m_2, m_3, m_4\} - \{m_3\} = \{m_1, m_2, m_4\}$. O conjunto de coberturas em D^+ que podem causar uma manifestação m_i é dado por $D_j^+ = \{D_k \mid D_k \in D^+, D_k \cap \text{causas}(m_i) \neq \emptyset\}$. No exemplo anterior, se $\text{causas}(m_2) = \{d_2, d_5\}$ então $D_2^+ = \{\{d_2, d_3\}\}$.

No exemplo de doenças de milho, o fitopatologista obteve o seguinte conjunto de hipóteses iniciais durante o processo de diagnóstico $D^+ = \text{SOL}_d = \{\{d_{10}\}, \{d_{18}, d_2\}\}$, onde $(\{d_{10}\}) = .75$ e $(\{d_{18}, d_2\}) = .33$. Neste exemplo tem-se $D^+ = \{d_{10}, d_{18}, d_2\}$, $M^+ \cup M^- = \{m_1, m_{13}, m_{19}, m_{56}, m_{20}\}$. Dado que $\text{efeitos}(d_2) = \{m_1, m_2, m_3\}$, $\text{efeitos}(d_{10}) = \{m_1, m_2, m_{13}, m_{19}, m_{23}, m_{56}\}$ e $\text{efeitos}(d_{18}) = \{m_3, m_{13}, m_{19}, m_{27}, m_{28}\}$, as manifestações $M^+ = \{m_2, m_3, m_{23}, m_{27}, m_{28}\}$, precisam ser investigadas (por exemplo através de testes laboratoriais) para que um diagnóstico correto possa ser formulado. A partir da KB_e tem-se que:

- $D_2^+ = \{d_1, d_2, d_{10}\}$ tal que $R(d_1, m_2) = 1.0$, $R(d_2, m_2) = 1.0$ e $R(d_{10}, m_2) = 0.75$.
- $D_3^+ = \{d_1, d_2, d_{18}, d_{33}, d_{35}\}$ tal que $R(d_1, m_3) = .75$, $R(d_2, m_3) = .5$, $R(d_{18}, m_3) = .75$, $R(d_{33}, m_3) = 1.0$ e $R(d_{35}, m_3) = .75$.
- $D_{23}^+ = \{d_{10}\}$ tal que $R(d_{10}, m_{23}) = 1.0$. $D_{27}^+ = \{d_{18}\}$ tal que $R(d_{18}, m_{27}) = 1.0$.
- $D_{28}^+ = \{d_{18}, d_{22}\}$ tal que $R(d_{18}, m_{28}) = .5$ e $R(d_{22}, m_{28}) = .75$.

Neste trabalho, uma classificação em termos de prioridade para o conjunto de exames plausíveis E (exames ou testes laboratoriais) é obtida a partir da verificação da consistência entre a base de conhecimento KB_e e a informação disponível num dado momento sobre um caso particular CA . A classificação dos exames é feita da seguinte maneira:

- Para cada manifestação $m_j \in M^+$, encontra-se uma distribuição $\delta_j: D_j^+ \rightarrow [0, 1]$, que indica o quanto a confirmação da manifestação m_j é importante para a confirmação de cada hipótese $D_k \in D_j^+$.
- Para cada manifestação $m_j \in M^+$, calcula-se um índice $f(m_j)$, obtido em função da distribuição δ_j , que mede a importância geral de m_j em termos do quanto a comprovação de sua existência (ou ausência) diminui a dificuldade de se escolher, dentre as hipóteses em D^+ , qual a mais adequada para explicar o caso.
- A partir da classificação das manifestações, obtida através do índice f , encontram-se quais os exames são os mais prioritários para o caso. Os exames que verificam a existência de m_j serão tanto mais prioritários quanto melhor for a classificação de m_j .

Eventualmente, em uma última etapa de classificação poderiam ser considerados fatores como custo e risco (no caso de exames intrusivos) que poderiam ajudar a refinar a escolha do melhor conjunto de exames a serem feitos. Este aspecto, embora simples de ser tratado, ainda não foi formalmente considerado neste trabalho.

Em relação à questão do raciocínio abduutivo, parte-se aqui do princípio que são os exames que são adequados à determinação da existência de uma dada manifestação (exames \rightarrow manifestações). Como o que se tem (ou supõe-se ter) são manifestações, o raciocínio é pois abduutivo. Para tal, é utilizada a noção de coberturas irredundantes da TCP. No entanto, na tarefa de investigação quando

se considerar somente coberturas unitárias de exames em E, o critério de parcimônia não é significativo.

Em Massruhá (2003) foram discutidas duas funções (f_{owa} e f_U) para medir a entropia de uma distribuição de valores $\delta_j: \Omega \rightarrow]0, 1]$, sem quaisquer restrições. A primeira função (f_{owa}) proposta é baseada na família dos operadores de médias ponderadas OWA - Ordered Weighted Averaging (Yager, 1993) como definida a seguir.

Definição 19. Seja $A = [a_1, \dots, a_n]$ um vetor com valores em R. Seja $W = [w_1, \dots, w_n]$ um vetor de pesos tal que $\forall_k, w_k \in [0, 1]$ e $\sum_{k=1}^n w_k = 1$. Cada vetor W determina um operador OWA, dado por

$$\Psi W(A) = \sum_{k=1}^n w_k u_k,$$

onde u_k é o k-ésimo maior elemento de $[a_1, \dots, a_n]$.

A segunda função (f_U) proposta é baseada na medida de incerteza U (eq. 1), apresentada em Klir e Folger (1988).

Definição 20. Seja Ω um domínio qualquer e $A = [a_1, \dots, a_n]$ um vetor com n posições, onde $a_i \in \Omega$. Suponha que $\exists a_k \in A, a_k = 1$, ou seja, que a distribuição modelada por A é normalizada em termos possibilísticos. Seja $T(A) = \{\rho \mid \exists a_k = \rho, a_k \in A\}$ o conjunto dos valores dos elementos de A (imagem de A). Seja $\langle \sigma_1, \dots, \sigma_q \rangle, q = |T(A)|$ a seqüência obtida através da ordenação decrescente dos valores em T(A); portanto, $\sigma_1 = 1$. Seja $\sigma_{q+1} = 0$. Então, tem-se

$$U(A) = \sum_{1 \leq i \leq n} (\sigma_i - \sigma_{i+1}) \log |A_i| \tag{1}$$

onde $A_i = \{a_k \mid a_k \geq \sigma_i\}$.

Suponha que seja utilizada a medida de não-especificidade citada no cálculo da força de m_j . Suponha que cada $a_k \in]0, 1]$ em A_j é tal que $a_k = \delta_j(D_k), D_k \in D_j^+, n = |D_j^+|$. Para isso, primeiramente, será transformada a distribuição de valores em A_j em uma distribuição normalizada $A'_j = [a_1/s, \dots, a_n/s]$ com $s = \max_{1 \leq k \leq n} a_k$ e depois será acrescentado o valor $(1 - \max\{a_1, \dots, a_n\})$.

Definição 21. A função $f_U(A_j)$ especifica a força de m_j para investigação através da fórmula a seguir:

$$f_U(A_j) = U(A'_j) + (1 - \max\{a_1, \dots, a_n\}) \tag{2}$$

Três casos especiais na aplicação da fórmula 2 são:

- Se $\sigma_1 = \dots = \sigma_q = 1$ então $f_U(A_j) = U(A'_j) = \log q$;
- Se $\sigma_1 = 1, \sigma_2 = \dots = \sigma_q = \alpha$ então $f_U(A_j) = U(A'_j) = \alpha \log q$;
- Se $\sigma_1 = \dots = \sigma_q = \alpha$ então $U(A'_j) = \log q$ e $f_U(A_j) = (1 - \alpha) + \log q$.

Em Massruhá (2003), pode-se observar que as duas funções geram praticamente a mesma classificação; para ambas funções têm-se $m_i \leq m_{i+1}$, onde $m_i \leq m_{i+1}$ se a entropia de A_i for menor que a entropia de A_{i+1} . Apresentadas as funções de entropia a serem aplicadas em distribuições de valores, resta ainda definir o que representam exatamente estas distribuições. As definições seguintes apresentam duas possíveis alternativas.

Definição 22. Uma distribuição de valores $\delta_j: D_j^+ \rightarrow [0, 1]$, que indica o quanto $m_j \in$ efeitos(D^+), tal que $m_j \notin M^+ \cup M^-$, é importante para uma dada cobertura $D_k \in D_r^+$, pode ser calculada como:

$$\begin{aligned} \text{(a)} \quad \delta_j(D_k) &= \perp_{di} \in D_k R(d_i, m_j), \\ \text{(b)} \quad \delta_j^+(D_k) &= \perp_{di} \in D_k T(R(d_i, m_j), \alpha_j^+(d_i, m_j)), \\ \delta_j^-(D_k) &= \perp_{di} \in D_k T(R(d_i, m_j), \alpha_j^-(d_i, m_j)) \end{aligned}$$

onde $R(d_i, m_j)$ refere-se ao grau de associação causal nebulosa de cada desordem d_i para cada manifestação m_j (Tabela 1), $\alpha_j^+(d_i)$ refere-se ao grau de consistência temporal de d_i dado que a presença da manifestação m_j é confirmada e $\alpha_j^-(d_i)$ refere-se ao grau de consistência temporal de d_i dado que a ausência da manifestação m_j é confirmada, T é uma t-norma e \perp é uma t-conorma.

No caso (b), as entropias de δ_j^+ e δ_j^- são posteriormente agregadas através da fórmula 3:

$$f_j = T(f(\delta_j^+), f(\delta_j^-)) \quad (3)$$

onde T é uma t-norma e $f(.)$ refere-se a uma das funções de entropia f_{owb} ou f_U .

Exemplos de t-conormas que podem ser utilizadas para modelar \perp são, por exemplo, $\perp^{\max}(a,b) = \max(a,b)$ e $\perp^{\text{prod}}(a,b) = (a+b-ab)$ que são as duas das t-normas min e produto (*), respectivamente. Por exemplo, sejam as distribuições $A_1 = [0.5, 0.7]$ e $A_2 = [0.3, 0.7]$. Para A_1 temos então $\perp^{\max}(0.5, 0.7) = 0.7$ e $\perp^{\text{prod}}(0.5, 0.7) = 0.85$. Para A_2 temos $\perp^{\max}(0.5, 0.7) = 0.7$ e $\perp^{\text{prod}}(0.5, 0.7) = 0.79$. Neste trabalho, foi adotada a t-conorma \perp^{prod} porque ela produz resultados mais diferenciados do que a t-conorma max usualmente empregada em aplicações envolvendo conjuntos nebulosos. Pelo mesmo motivo, neste trabalho, utiliza-se a t-norma produto (*) para modelar T ao invés da t-norma usual min, tanto na definição 22(b) quanto na fórmula 3. Maiores detalhes das definições de t-norma e t-conorma podem ser encontrados em Massruhá (2003).

Ao retornar ao exemplo de doenças de milho em que o fitopatologista obteve o seguinte conjunto de hipóteses iniciais durante o processo de diagnóstico $D^+ = \text{SOL}_d = \{\{d_{10}\}, \{d_{18}, d_2\}\}$, onde $\alpha(\{d_{10}\}) = 0.75$ e $\alpha(\{d_{18}, d_2\}) = 0.33$. Neste exemplo tem-se $D^+ = \{d_{10}, d_{18}, d_2\}$, $M^+ \cup M^- = \{m_1, m_{13}, m_{19}, m_{56}, m_{20}\}$. Dado que efeitos(d_2) = $\{m_1, m_2, m_3\}$, efeitos(d_{10}) = $\{m_1, m_2, m_{13}, m_{19}, m_{23}, m_{56}\}$ e efeitos(d_{18}) = $\{m_3, m_{13}, m_{19}, m_{27}, m_{28}\}$, as manifestações $M^+ = \{m_2, m_3, m_{23}, m_{27}, m_{28}\}$, precisam ser investigadas (por exemplo através de testes laboratoriais) para que um diagnóstico correto possa ser formulado.

Para selecionar as manifestações prioritárias a serem investigadas é utilizada a fórmula 2. A partir da KB_e tem-se que:

- $D_2^+ = \{d_1, d_2, d_{10}\}$ tal que $R(d_1, m_2) = 1.0$, $R(d_2, m_2) = 1.0$ e $R(d_{10}, m_2) = 0.75$.
- $D_3^+ = \{d_1, d_2, d_{18}, d_{33}, d_{35}\}$ tal que $R(d_1, m_3) = 0.75$, $R(d_2, m_3) = 0.5$, $R(d_{18}, m_3) = 0.75$, $R(d_{33}, m_3) = 1.0$ e $R(d_{35}, m_3) = 0.75$.
- $D_{23}^+ = \{d_{10}\}$ tal que $R(d_{10}, m_{23}) = 1.0$.
- $D_{27}^+ = \{d_{18}\}$ tal que $R(d_{18}, m_{27}) = 1.0$.
- $D_{28}^+ = \{d_{18}, d_{22}\}$ tal que $R(d_{18}, m_{28}) = 0.5$ e $R(d_{22}, m_{28}) = 0.75$.

Observe que $\{m_{23}\}$ e $\{m_{27}\}$ são manifestações necessárias para confirmação das desordens d_{10} e d_{18} respectivamente. Portanto, durante a investigação, a confirmação da presença ou ausência de m_{23} auxilia na confirmação ou na refutação da desordem d_{10} na hipótese diagnóstica. Similarmente, a confirmação da presença ou ausência de m_{27} auxilia na confirmação ou na refutação da desordem d_{18} na hipótese diagnóstica. Enquanto as manifestações $\{m_2, m_3, m_{28}\}$ não necessariamente contribuirão para otimização da hipótese diagnóstica, pois, são manifestações possíveis de acontecer com diferentes graus de importância.

Assim após aplicar a função de entropia f_{owar} , os exames laboratoriais (E) que identificam as manifestações $\{m_2, m_3, m_{23}, m_{27}, m_{28}\}$ na Kb_e devem ser solicitados na ordem (exames(m_{23}) \prec exames(m_{27}) \prec exames(m_{28}) \prec exames(m_2) \prec exames(m_3)) visando confirmar ou refutar as hipóteses que causam estes efeitos. Portanto, a investigação deve começar pela m_{23} que é uma manifestação específica da desordem d_{10} , pois a confirmação de sua presença garante que a hipótese d_{10} é a desordem que cobre o caso particular apresentado como exemplo. Como apresentado na Tabela 9, a confirmação desta manifestação pode ser obtida através de uma análise-macroscópica. Caso não seja possível identificar a manifestação 'in loco', pode-se executar outros exames descritos na lista acima, como microscopia ótica, testes sorológicos para tentar identificar a causa dos sintomas apresentados no caso. Após a confirmação de m_{23} , com a informação completa do caso particular, pode-se executar novamente o programa o módulo de diagnóstico para refinar o conjunto de hipóteses.

A partir das idéias acima, pode-se definir formalmente a seleção de exames ou testes laboratoriais para investigação.

Definição 23. (Solução abduativa) Dado uma base de conhecimento $KB_e = \langle E, I, D, M, R \rangle$ e uma hipótese $D_i \in SOL_d$ para um conjunto de observações M^+ tal que $\alpha(D_i) < \Delta$, SOL_e , é uma solução abduativa a partir de E para M^+ ordenadas se $I \cup SOL_e$ cobre M^+ e $I \cup SOL_e$ é consistente.

A partir de SOL_e um conjunto de manifestações são confirmadas ou refutadas, conseqüentemente, atualizando os conjuntos de manifestações de M^+ e M^- que pertencem a CA gerando um novo caso C_{atual} . Dado a base de conhecimento KB_e e

o caso particular C_{atual} , infere-se um nova explicação abduativa SOL_{α} a partir da definição 14. Para toda $D_i \in SOL_{\alpha}$ onde $\alpha(D_i) < \Delta$, pode-se inferir os melhores tratamentos através de um ambiente abduativo para tratamentos como será apresentado a seguir.

No exemplo de doenças de milho, após a confirmação de m_{23} , com a informação completa do caso particular obtém-se um resultado onde $SOL_{\alpha} = \{d_{10}\}$ onde $\alpha(\{d_{10}\}) = 0.5$.

Observe que o grau de certeza da hipótese d_{10} abaixou de 0.75 para 0.5 após o refinamento da informação e o grau de certeza da hipótese $\{d_{18}, d_2\}$ tornou-se incompatível (grau de certeza = 0) como consequência da diminuição do grau de entropia diagnóstica (incerteza). Por outro lado, obteve-se uma maior diferenciação das hipóteses que pertencem a solução abduativa SOL_{α} .

O conhecimento do especialista ou diagnosticador em um dado domínio não se resume apenas em fazer classificações corretas mas também se baseia no mapeamento correto do diagnóstico em tratamentos efetivos. Para cada desordem d_i tem-se uma árvore de decisão associada. Por exemplo, durante o processo de raciocínio clínico, o diagnosticador tem que tomar a decisão de quando aplicar (A) ou não aplicar ($\neg A$) um fungicida. Entretanto, a representação de todas as árvores de decisão para todos os tratamentos de todas desordens é muito trabalhosa e difícil (Massruhá, 2003). No escopo da TCN é proposta uma solução alternativa na área de tomada de decisão em tratamentos para o qual se utiliza dois conjuntos finitos conforme descrito a seguir.

Definição 24. A base de conhecimento KB_i é representada por uma quintupla $\langle T, D, Z, CC, V \rangle$, onde:

- T é o conjunto de tratamentos ou medidas de controle;
- D é o conjunto de desordens (doenças, falhas);
- $Z \subseteq T \times D$ é uma relação para modelar associações entre tratamentos e desordens onde cada par $\langle t_k, d_i \rangle \in Z$ significa t_k pode tratar d_i e está associado com um conjunto de condições de controle CC e um conjunto de variáveis V ;
- CC é um conjunto de condições de controle que deve ser consistente com o caso particular para garantir que determinado tratamento t_k é eficiente para controlar uma determinada desordem d_i , representada pelo conjunto $CC = \{CF, SEV, EP\}$ (definição 25);
- V é o conjunto de variáveis $\{GCONT, GEVOL, CUSTO, GANHO\}$ que auxilia na tomada de decisão para tratamentos (definição 26).

O conjunto de variáveis CC e V também são modelados por intervalos nebulosos trapezoidais. A definição formal de CC e V está descrita a seguir.

Definição 25. As condições de controle de uma dupla $\langle t_k, d_i \rangle$ é representada pelo conjunto $CC = \{CF, SEV, EP\}$ onde:

- CF corresponde às condições que favorecem a eficácia de um tratamento t_k para uma desordem d_i ;
- SEV corresponde a um grau nebuloso trapezoidal de intensidade ou severidade de uma desordem d_i que favorece a eficácia de um tratamento t_k para uma desordem d_i ;
- EP corresponde a um intervalo nebuloso que representa a fase de desenvolvimento ou idade de um determinado paciente ou planta que favorecem a eficácia de um tratamento t_k para uma desordem d_i .

O conjunto CF depende totalmente do domínio de aplicação. No contexto de fitopatologia $CF = (TEMP, UMID)$ são intervalos nebulosos relativos à temperatura (Tabela 6) e umidade (Tabela 7) favoráveis para tratar uma desordem d_i usando tratamento t_k .

Definição 26. A expectativa de controle associada para cada dupla $Z = \langle t_k, d_i \rangle$ é representada pelo conjunto de variáveis $V = \{GCONT, GEVOL, CUSTO, GANHO\}$, onde:

- $GCONT \in [0, 1]$ corresponde ao grau efetivo de controle de um tratamento t_k para uma desordem d_i caso as condições em CC sejam satisfeitas;
- $GEVOL \in [0, 1]$ corresponde ao grau de evolução de uma determinada desordem d_i quando aplicado um tratamento t_k em determinadas condições de controle CC;
- CUSTO é o intervalo nebuloso que representa o custo associado ao tratamento t_k para uma desordem d_i ;
- GANHO é o intervalo nebuloso que corresponde a produtividade esperada quando um determinado tratamento t_k é aplicado para uma determinada desordem d_i .

A explicação mais plausível de tratamento é aquela que tem o maior GCONT, o menor GEVOL e CUSTO e o melhor GANHO. Observe ainda que está sendo suposto que os intervalos nebulosos das variáveis GANHO e CUSTO estão no mesmo universo de discurso (ex.: sacas/ha). Entretanto, os valores dos intervalos nebulosos devem ser mapeados para $[0, 1]$ quando estes não estiverem no mesmo universo de discurso. As variáveis GCONT e GEVOL correspondem a possibilidade de um tratamento t_k ser efetivo (Π_e) ou a possibilidade de um tratamento t_k não ser efetivo ($\Pi_{\bar{e}}$).

Para um problema de tratamentos representado por KB_r , é conveniente e útil definir os conjuntos ou funções baseadas na relação Z.

Definição 27. Para todo $t_k \in T$ e $d_i \in D$ em uma base de conhecimento KB_r :

- Indicações $(t_k) = \{d_i \mid \langle t_k, d_i \rangle \in Z\}$, o conjunto dos elementos diretamente controlados por t_k ;

- Tratamentos $(d_i) = \{t_k \mid <t_k, d_i> \in Z\}$, o conjunto dos elementos que podem diretamente controlar ou tratar d_i .

Os conjuntos definidos podem facilmente ser generalizados de indicações e tratamentos individuais para conjuntos de indicações e tratamentos similarmente a generalização apresentada na definição 9.

Para ilustrar a representação de conhecimento em $KB_t = \langle T, D, Z, CC, V \rangle$ serão considerados cinco fungicidas que podem ser aplicados como tratamentos alternativos para Cercosporiose (d_{10}) (Tabela 10). Os intervalos nebulosos das Variáveis auxiliares correspondentes a cada um destes fungicidas foram obtidos de um experimento com estes fungicidas (Morandi & Menezes, 2002). Na Tabela 10 estão representadas as tuplas referentes a cada tratamento em Kb_t .

Tabela 10. Tupla correspondente a representação dos tratamentos para a desordem Cercospora d_{10} em Kb_t .

T	D	$Z = <t_k, d_{10}>$	$CC = (EP, SEV, CF = (TEMP, HUMID))$	$V = (GCONT, GEV OL, CUSTO, GANHO)$
T_1 : FUNGICIDA1	d_{10}	$<t_1, d_{10}>$	$=(\{0,17\}, \{1,4\}, \{[25,30,45,50], [80,85,95,100]\})$	$(1.0, 0, [10,20,30,40], [100,112,118,120])$
T_2 : FUNGICIDA2		$<t_2, d_{10}>$	$(\{0,17\}, \{1,4\}, \{[25,30,45,50], [80,85,95,100]\})$	$(1.0, 0, [10,10,20,20], [100,112,118,120])$
T_3 : FUNGICIDA3		$<t_3, d_{10}>$	$(\{0,17\}, \{1,4\}, \{[25,30,45,50], [80,85,95,100]\})$	$(1.0, 0.5, [10,20,30,40], [90,102,108,110])$
T_4 : FUNGICIDA4		$<t_4, d_{10}>$	$(\{0,17\}, \{1,4\}, \{[25,30,45,50], [80,85,95,100]\})$	$(1.0, 0.5, [10,20,30,40], [90,102,108,110])$
T_5 : FUNGICIDA5		$<t_5, d_{10}>$	$(\{0,17\}, \{1,4\}, \{[25,30,45,50], [80,85,95,100]\})$	$(1.0, 0.5, [10,20,30,40], [90,102,108,110])$
T_{15} : NENHUM		$<t_{15}, d_{10}>$	$(\{0,17\}, \{1,4\}, \{[25,30,45,50], [80,85,95,100]\})$	$(0.5, 1.0, [0,0,0,0], [50,70,80,100])$

No exemplo de milho, os valores de produtividade normal são intervalos entre 100-120 unidades. Os intervalos de produtividade esperada GANHO são calculados a partir da produtividade normal. Na Tabela 10, quando nenhum tratamento é aplicado (T_{15}) a produtividade é baixa. Quando os tratamentos (T_1, T_2, T_3, T_4, T_5) são aplicados a produtividade esperada é mais alta.

Para complementar a formulação do problema necessita-se da representação do caso particular que será apresentada a seguir.

Definição 28. A informação sobre um caso particular na etapa de tratamentos é modelada por uma dupla $CA^* = \langle D^+, CC^+ \rangle$ onde:

- $D^+ \subseteq \wp(D)$ é o conjunto de desordens presentes conhecidas no caso;
- $CC^+ = (CF^+, SEV^+, EP^+)$ são as condições externas em que ocorreram os sintomas, onde CF^+ é uma função que associa as condições de temperatura e umidade ($TEMP^+, UMID^+$) no momento do diagnóstico, SEV^+ e EP^+ são as funções que associam a severidade de cada $m_j \in M^+$ e a fase em que elas ocorreram, respectivamente.

Uma vez caracterizado os problemas de diagnóstico, investigação e tratamentos ($P = \langle KB_d, KB_e, KB_t, CA^* \rangle$), caracteriza-se agora as soluções para o problema de

tratamentos, denominado $SOL_t(P)$. Para isto, além da noção de "cobertura"; utiliza-se outros índices de consistência e coberturas nebulosas que serão descritos a seguir.

Definição 29. (Solução abdutiva) Dado uma base de conhecimento $KB_t = \langle T, D, Z, CC, V \rangle$ e uma hipótese $D_i \in SOL_d \subseteq D$, SOL_t é uma solução abdutiva para D_i a partir de T sse $Z \cup SOL_t$ cobre D_i , $Z \cup SOL_t$ e $CC \cup SOL_t$ sejam consistente e V é máximo.

Retomando o exemplo em fitopatologia tem-se CA^* onde $D^* = SOL_d = \{d10\}$, $CC^+ = (CF^+, SEV^+, EP^+)$, $CF^+ = (TEMP^+, UMID^+) = (\langle 22, 23, 24, 25 \rangle, \langle 80, 85, 87, 90 \rangle)$, $SEV^+ = \langle 3, 4, 5, 6 \rangle$ e $EP^+ = \langle 8, 9 \rangle$.

Na seqüência será discutida a consistência entre o modelo e o caso e a otimização das variáveis V .

Os tratamentos mais plausíveis T (remédios, fungicidas), para um dado caso, devem ser inferidas abdutivamente a partir da consistência entre a informação sobre as hipóteses mais plausíveis $D_i \in SOL_d \subseteq D$ (desordens potenciais) e uma base de conhecimento $KB_t = \langle T, D, Z, CC, V \rangle$. No escopo deste trabalho, são utilizados os índices de consistência de intensidade propostos em Wainer & Sandri (1998) para calcular a consistência entre o modelo e o caso.

Definição 30. O grau de consistência das condições de controle de uma dupla $\langle t_k, d_i \rangle$ e um caso particular CA é calculado através da fórmula $\gamma(t_k, d_i) = \inf_{c_k \in CC} \gamma(c_k)$ de modo que $\gamma(c_k) = h(INT(c_k) \cap INT^+(c_k))$, $INT(c_k)$ corresponde a intensidade de $c_k \in CC$ em KB_t e $INT^+(c_k)$ corresponde a intensidade de cada $c_k \in CC^+$.

Definição 31. Seja CC as condições de controle de uma dupla $\langle t_k, d_i \rangle$. Seja $INT(c_k)$ o intervalo nebuloso associado com cada condição de controle $c_k \in CC$ e $INT^+(c_k)$ o intervalo nebuloso correspondente a intensidade de cada $c_k \in CC$ no caso particular. O grau de consistência entre $\langle t_k, d_i \rangle$ e um caso específico é calculado por $\gamma(t_k, d_i) = \inf_{c_k \in CC} \gamma(c_k)$, onde $\gamma(c_k) = h(INT(c_k) \cap INT^+(c_k))$.

Definição 32. O grau de consistência das condições de controle de um determinado tratamento t_k em relação a um determinada cobertura $D_i \in D^*$, é calculada por $\gamma(t_k, D_i) = \inf_{d_i \in D_i} \gamma(t_k, d_i)$ onde $\gamma(t_k, D_i) > 0, \forall D_i \subseteq D^*, t_k \in T^*$.

Adicionalmente, no escopo da TCN é possível estreitar as possíveis decisões terapêuticas através do conjunto de variáveis

$V = \{GCONT, GEVOL, CUSTO, GANHO\}$ como definido a seguir.

Definição 33. Um determinado tratamento t_k para uma determinada desordem d_i que explica um caso particular CA é mais plausível se:

- a consistência de CF, SEV, EP é máxima,
- o $GCONT(t_k)$ é máximo,
- o $GEVOL(t_k)$ é mínimo, e
- o $RETORNO(t_k)$ é máximo onde $RETORNO(t_k)$ é calculado em função das variáveis $CUSTO(t_k)$ e $GANHO(t_k)$ como definido na equação 4.

$$RETORNO(t_k) = GANHO_{\text{produtividade}}(t_k) \ominus CUSTO(t_k) \quad (4)$$

A partir de uma base de conhecimento KB_t e um conjunto de hipóteses $D^* \subseteq \wp(D)$, que explica um caso específico, a solução abduativa para um problema de tratamentos SOL_t pode ser definida tal como descrita na definição 29.

Definição 34. A plausibilidade de um conjunto de tratamentos T^* para uma determinada cobertura D_i é calculada como

$$SOL_t = \max_{\forall d_i \in DI, tk \in T^*} RETORNO(z_{k,i})$$

e

$$\gamma(t_k, D_i) > 0, \forall DI \subseteq D^*, tk \in T^*.$$

A seguir será apresentado um exemplo em fitopatologia para ilustrar as definições acima. Seja $KB_t = \langle T, D, Z, CC, V \rangle$ uma base de conhecimento, tal que $T = \{T_1, T_2, T_3, T_4, T_5, T_{15}\}$ são coberturas irredundantes para $D^* = \{d_{10}\}$. Para cada $z_{k,i} = \langle t_k, d_i \rangle$ tem-se os valores $CC_{k,i}$ e $V_{k,i}$ como apresentados na Tabela 10.

Considerando novamente o exemplo em fitopatologia em que tem-se o caso particular CA^* onde $D^* = \{d_{10}\}$, os tratamentos mais plausíveis a partir da base de conhecimento KB_t para este caso são $\{t_1, t_2, t_3, t_4, t_5, t_{15}\}$ desde que todos são coberturas irredundantes.

Primeiramente, no processo de tomada de decisão para tratamentos, tem-se que calcular o índice de consistência entre tratamentos e informação do caso $\gamma(t_k, d) = \inf_{ck \in CC}$ tal como descrito na definição 30. No exemplo dado (Tabela 11), ao considerar as condições de controle CC sem considerar as variáveis V, todos os tratamentos são plausíveis para tratar d_{10} .

Na Tabela 12 tem-se informação adicional onde $GCONT_{t_1} = GCONT_{t_2} = GCONT_{t_3} = GCONT_{t_4} = GCONT_{t_5} = 1.0$ e $GCONT_{t_{15}} = 0$. Entretanto, $\{t_1, t_2, t_3, t_4, t_5, t_{15}\}$ não são distinguíveis. Adicionalmente, considerando $GEVOL_{t_1} = GEVOL_{t_2} = 0$, $GEVOL_{t_3} = GEVOL_{t_4} = GEVOL_{t_5} = 0.5$ e $GEVOL_{t_{15}} = 1.0$, t_1 e t_2 não são distinguíveis ainda.

Neste caso, o especialista deve considerar na sua tomada de decisão outras variáveis tais como CUSTO e GANHO (definição 33). Retomando o exemplo em fitopatologia (Tabela 12) tem-se $CUSTO(t_1) = \langle 10, 20, 30, 40 \rangle$, $CUSTO(t_2) = \langle 10, 10, 20, 20 \rangle$, $GANHO(t_1) = \langle 100, 112, 118, 120 \rangle$ e $GANHO(t_2) = \langle 100, 112, 118, 120 \rangle$. Assim, o especialista pode usar os valores para escolher o tratamento que gera um melhor retorno. Tem-se $RETORNO(t_1) =$

$< 100, 112, 118, 120 > \ominus < 10, 20, 30, 40 > = < 60, 82, 98, 110 > \ominus$
 $\text{RETORNO}(t_2) = < 100, 112, 118, 120 > \ominus < 10, 10, 20, 20 > =$
 $< 80, 92, 108, 110 >$ como representado na Fig. 4.

Tabela 11. Índices de consistência referente às condições de controle associados para cada $z_{k,i} = < t_k, d_i > \in Z$.

T	D	Z = < t _k , d ₁₀ >	((EP), (SEV), (CF))	(t _k , d ₁₀ = inf _{ck} (c _k))
T ₁ : FUNGICIDA1	d ₁₀	< t ₁ .d ₁₀ >	(EP) = h(< 0, 0, 17, 17 > n < 8, 8, 9, 9 >) = 1.0 (SEV) = h(< 1, 2, 3, 4 > n < 3, 4, 5, 6 >) = 0.5 (CF) (TEMP) = h(< 25, 30, 45, 50 > n < 22, 23, 24, 25 >) = 1.0 (HUMID) = h(< 25, 30, 45, 50 > n < 80, 85, 87, 90 >) = 1.0	(t ₁ .d ₁₀) = 0.5
T ₂ : FUNGICIDA2	d ₁₀	< t ₂ .d ₁₀ >	(EP) = h(< 0, 0, 17, 17 > n < 8, 8, 9, 9 >) = 1.0 (SEV) = h(< 1, 2, 3, 4 > n < 3, 4, 5, 6 >) = 0.5 (CF) (TEMP) = h(< 25, 30, 45, 50 > n < 22, 23, 24, 25 >) = 1.0 (HUMID) = h(< 25, 30, 45, 50 > n < 80, 85, 87, 90 >) = 1.0	(t ₂ .d ₁₀) = 0.5
T ₃ : FUNGICIDA3	d ₁₀	< t ₃ .d ₁₀ >	(EP) = h(< 0, 0, 17, 17 > n < 8, 8, 9, 9 >) = 1.0 (SEV) = h(< 1, 2, 3, 4 > n < 3, 4, 5, 6 >) = 0.5 (CF) (TEMP) = h(< 25, 30, 45, 50 > n < 22, 23, 24, 25 >) = 1.0 (HUMID) = h(< 25, 30, 45, 50 > n < 80, 85, 87, 90 >) = 1.0	(t ₃ .d ₁₀) = 0.5
T ₄ : FUNGICIDA4	d ₁₀	< t ₄ .d ₁₀ >	(EP) = h(< 0, 0, 17, 17 > n < 8, 8, 9, 9 >) = 1.0 (SEV) = h(< 1, 2, 3, 4 > n < 3, 4, 5, 6 >) = 0.5 (CF) (TEMP) = h(< 25, 30, 45, 50 > n < 22, 23, 24, 25 >) = 1.0 (HUMID) = h(< 25, 30, 45, 50 > n < 80, 85, 87, 90 >) = 1.0	(t ₄ .d ₁₀) = 0.5
T ₅ : FUNGICIDA5	d ₁₀	< t ₅ .d ₁₀ >	(EP) = h(< 0, 0, 17, 17 > n < 8, 8, 9, 9 >) = 1.0 (SEV) = h(< 1, 2, 3, 4 > n < 3, 4, 5, 6 >) = 0.5 (CF) (TEMP) = h(< 25, 30, 45, 50 > n < 22, 23, 24, 25 >) = 1.0 (HUMID) = h(< 25, 30, 45, 50 > n < 80, 85, 87, 90 >) = 1.0	(t ₅ .d ₁₀) = 0.5
T ₁₅ : NENHUM	d ₁₀	< t ₁₅ .d ₁₀ >	(EP) = h(< 0, 0, 17, 17 > n < 8, 8, 9, 9 >) = 1.0 (SEV) = h(< 1, 2, 3, 4 > n < 3, 4, 5, 6 >) = 0.5 (CF) (TEMP) = h(< 25, 30, 45, 50 > n < 22, 23, 24, 25 >) = 1.0 (HUMID) = h(< 25, 30, 45, 50 > n < 80, 85, 87, 90 >) = 1.0	(t ₁₅ .d ₁₀) = 0.5

Tabela 12. Índices de consistência referente às variáveis V associados para cada $z_{k,i} = < t_k, d_i > \in Z$.

T	D	Z = < t _k , d ₁₀ >	GCONT	GEVOL	CUSTO	GANHO	RETORNO
T ₁ : FUNGICIDA1	d ₁₀	< t ₁ .d ₁₀ >	1.0	0	< 10, 20, 30, 40 >	< 100, 112, 118, 120 >	< 60, 82, 98, 110 >
T ₂ : FUNGICIDA2	d ₁₀	< t ₂ .d ₁₀ >	1.0	0	< 10, 10, 20, 20 >	< 100, 112, 118, 120 >	< 80, 92, 108, 110 >
T ₃ : FUNGICIDA3	d ₁₀	< t ₃ .d ₁₀ >	1.0	0.5	< 10, 20, 30, 40 >	< 90, 102, 108, 110 >	< 50, 72, 88, 100 >
T ₄ : FUNGICIDA4	d ₁₀	< t ₄ .d ₁₀ >	1.0	0.5	< 10, 20, 30, 40 >	<< 90, 102, 108, 110 >>	< 50, 72, 88, 100 >
T ₅ : FUNGICIDA5	d ₁₀	< t ₅ .d ₁₀ >	1.0	0.5	< 10, 20, 30, 40 >	< 90, 102, 108, 110 >	< 50, 72, 88, 100 >
T ₁₅ : NENHUM	d ₁₀	< t ₁₅ .d ₁₀ >	0	1.0	< 0, 0, 0, 0 >	< 50, 70, 80, 100 >	< 50, 70, 80, 100 >

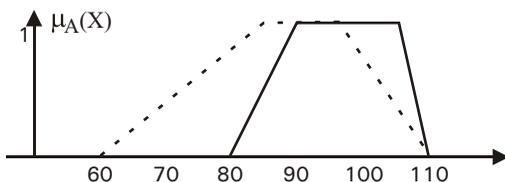


Fig. 4. Intervalos nebulosos associados para $\text{RETORNO}(t_1)$ e $\text{RETORNO}(t_2)$.

Observe que não é trivial escolher qual é a melhor hipótese tal como descrita na definição 34 desde que, por um lado, t_1 pode dar um maior retorno (110 unidades) mas por outro lado, ele pode dar o pior retorno (60 unidades).

No escopo deste trabalho está sendo utilizado os índices globais *exceedance* propostos em Dubois & Prade (1988). Dado dois intervalos nebulosos trapezoidais $P = \{p_1, p_2, p_3, p_4\}$ e $Q = \{q_1, q_2, q_3, q_4\}$ os 4 índices globais *exceedance* são calculados como: $I_1 = \max(0, \min(1, 1 + (p_3 - q_2)/(\beta + \gamma)))$, $I_2 = \max(0, \min(1, (p_2 - q_2 + \gamma)/(\alpha + \gamma)))$, $I_3 = \max(0, \min(1, (p_3 - q_3 + \beta)/(\beta + \delta)))$ e $I_4 = \max(0, \min(1, (p_2 - q_3)/(\alpha + \delta)))$.

Os valores dos quatro índices são calculados como apresentado na Tabela 13. Pelo índice I_1 não é possível diferenciar os dois intervalos, entretanto, pelos índices I_2 , I_3 e I_4 torna-se claro que R_2 é maior que R_1 . Portanto, t_2 é o tratamento mais plausível para o caso particular apresentado.

Tabela 13. Índices para o caso CA*.

	I_1	I_2	I_3	I_4
R_1	1	2/34	2/14	-26/24
R_2	1	32/34	12/14	-1/4

Finalmente, pode-se concluir que a partir das definições 14, 23 e 29 e das definições complementares apresentadas, completa-se a formalização da definição 2, onde dada uma base de conhecimento $= \{KB_d, Kb_e, KB_s\}$ para o problema de raciocínio clínico P e um caso particular CA, $SOL(P) = \{SOL_d, SOL_e, SOL_s\}$ é uma solução abduativa para caso particular CA. Em Massruhá (2003) estão apresentados os algoritmos desenvolvidos para implementar os mecanismos de inferência dos ambientes abduativos para diagnóstico, investigação e tratamentos apresentados nesta seção. A seguir serão apresentados alguns resultados obtidos na validação da TCN.

Resultados e Discussão

Nesta seção são apresentados os resultados obtidos durante a solução do caso de diagnóstico, investigação e tratamento de doenças de milho, apresentado no decorrer deste trabalho. A linguagem utilizada na implementação dos algoritmos da TCN foi o AMZI PROLOG devido a sua sintaxe e aderência ao problema (Amzi..., 2004). Adicionalmente, a implementação em PROLOG facilitou a comparação da TCN com o TCP original e TCP temporal através das ferramentas que também foram desenvolvidas em PROLOG no escopo do trabalho de Wainer & Rezende (1997).

Os programas em PROLOG que compõem a TCN são claramente divididos em três partes: base de conhecimento, mecanismo de inferência e especificação do caso particular. O mecanismo de inferência abduutivo, apresentado na seção de Material e Métodos, foi implementado através dos algoritmos: `bipartido_nebuloso`, `exames_nebulosos` e `tratamentos_nebulosos`.

Na Tabela 14 são apresentados os resultados obtidos na fase de diagnóstico. Na terceira coluna da Tabela 14 são descritos os resultados obtidos após processar a informação do caso pelo programa `bipartido_nebuloso.pro`. Na primeira coluna estão descritos os resultados obtidos ao rodar o mesmo caso particular sem considerar informação temporal e nebulosa no programa `bipartido.pro`. Na segunda coluna são descritos os resultados obtidos ao rodar o caso no programa `temporal_pct.pro` que utiliza intervalos bem definidos.

Tabela 14. Comparação de algoritmos na fase de diagnóstico.

<i>Bipartido</i>	<i>Bipartido-temporal</i>	<i>Bipartido-nebuloso</i>
[10]	[]	[10, [0.75]]
[8, 1]		[18, 2, [0.33]]
[8, 2]		
[10, 1]		
[10, 2]		
[18, 1]		
[18, 2]		

Observe na Tabela 14 que no escopo do TCP original (`bipartido`) foram geradas sete explicações plausíveis para este caso particular e debaixo da ferramenta que implementa o `bipartido-temporal.pro` nenhuma hipótese foi encontrada dentre as sete apresentadas para o mesmo caso no `bipartido.pro`. Já no contexto do TCP-nebuloso foram geradas apenas duas explicações plausíveis dentre as sete apresentadas inicialmente no TCP original. Portanto, no escopo do `bipartido_nebuloso.pro` obteve-se 86% de redução das hipóteses em relação ao `bipartido.pro`.

Adicionalmente, o grau de certeza associado a cada hipótese no `bipartido_nebuloso.pro` também auxilia o diagnosticador na tomada de decisão durante o diagnóstico. Nos resultados obtidos, observa-se que d_{10} é a explicação mais plausível. Portanto, o diagnosticador investiga outras manifestações de d_{10} . Ao confirmar novas manifestações presentes o diagnosticador pode rodar novamente o `bipartido-nebuloso` e obter os resultados apresentados na Tabela 15.

Tabela 15. Comparação de algoritmos na fase de diagnóstico.

<i>Bipartido</i>	<i>Bipartido-temporal</i>	<i>Bipartido-nebuloso</i>
[10] [10, 1] [10, 2]	[]	[10, [0.5]]

Observe na Tabela 15 que no escopo do TCP original foram geradas três explicações plausíveis para especificação completa do caso particular e debaixo da ferramenta que implementa o TCP-temporal nenhuma explicação foi encontrada para o mesmo caso. Já no contexto do TCP-nebuloso foi gerada apenas uma explicação plausível dentre as duas apresentadas inicialmente no TCP original (redução de 50% das hipóteses). Portanto, a utilização de intervalos nebulosos para modelar informação temporal mostrou-se mais eficiente do que o modelo TCP-temporal que utiliza intervalos bem definidos além de auxiliar na investigação e na redução do conjunto de hipóteses.

No escopo da investigação, pode-se comentar os resultados obtidos pelo algoritmo `exames_nebulosos.pro` que também é baseado no algoritmo bipartido (Tabela 16). Entretanto, no algoritmo `exames_nebulosos.pro` antes de aplicar os critérios de parcimônia de irredundância através da função `revise` permite selecionar as manifestações prioritárias a serem investigadas dentro do contexto das hipóteses consistentes.

Tabela 16. Análise dos algoritmos na fase de investigação.

<i>Exemplos</i>	<i>M⁺ ordenadas</i>	<i>SOL_d</i>	<i>SOL_e</i>
Exemplo 1	[m ₂₃ , m ₂₇ , m ₂₈ , m ₂ , m ₃]	[d ₁₀]	[análise – macroscópica] [microscopia – ótica] [isolamento – em - cultura - pura] [testes – sorológicos] [análise - DNA]
Exemplo 2	[m ₉ , m ₁₀ , m ₁₄ , m ₁₃]	[d ₃ , d ₄]	[análise – macroscópica] [microscopia – ática] [isolamento – em - cultura - pura] [testes – sorológicos] [análise - DNA]

Observe que a classificação de manifestações auxilia na tomada de decisão para diagnóstico como apresentado no Exemplo 1. Tais resultados são coerentes com o raciocínio do diagnosticador na fase de investigação e mostram como esta etapa pode contribuir para a tomada de decisão na etapa de diagnóstico.

No escopo da etapa de tratamentos, pode-se comentar os resultados obtidos pelo algoritmo `tratamentos_nebulosos.pro` que também é baseado no algoritmo bipartido (Tabela 17). Entretanto, o algoritmo `tratamentos_nebulosos.pro` antes de aplicar os critérios de parcimônia de irredundância através da função `revise`

Permite selecionar os tratamentos mais plausíveis dentro do contexto das hipóteses consistentes.

Tabela 17. Análise dos algoritmos na fase de tratamentos.

<i>Exemplos</i>	SOL_d	SOL_t
Exemplo 1	$[d_{10}]$	$[t_1, t_2]$
Exemplo 2	$[d_3, d_4]$	$[t_6]$

Observe que no primeiro exemplo, os fungicidas FUNGICIDA1 e FUNGICIDA2 são mais indicados para controle da Cercosporiose quando se considera variáveis como época do aparecimento da desordem, condições climáticas e a severidade da desordem. Inicialmente, no escopo do programa bipartido.pro aparecem 5 tipos de fungicidas indicados para controlar d_{10} : FUNGICIDA1, FUNGICIDA2, FUNGICIDA3, FUNGICIDA4 e FUNGICIDA5.

Portanto, no escopo do tratamentos_nebulosos.pro conseguiu-se reduzir três hipóteses.

Estes resultados correspondem aos resultados obtidos através de um experimento em campo (Morandi & Menezes, 2002) onde foram aplicados os cinco tipos de fungicidas para combater o fungo *Cercospora zea-maydis* e os fungicidas FUNGICIDA1 e FUNGICIDA2 foram mais eficientes ao considerar as variáveis época do aparecimento da desordem, condições climáticas e a severidade da desordem.

Na Tabela 17 também está apresentado um outro exemplo onde os resultados também são coerentes com o raciocínio do diagnosticador. Neste segundo exemplo, embora o diagnosticador não tenha certeza se o diagnóstico é d_3 ou d_4 , pode-se usar tratamento t_6 : - FUNGICIDA6, pois é um fungicida que serve para controlar as duas desordens.

Os algoritmos da TCN foram aplicados para as 41 desordens de milho e os resultados obtidos em todos os casos foram compatíveis com o raciocínio do diagnosticador. Embora a TCN seja uma ferramenta simples e poderosa para raciocínio de diagnóstico, investigação e tratamentos, o modelo proposto tem algumas limitações.

Uma de suas limitações está no escopo do problema é que o procedimento de monitoramento não está incluído no escopo deste trabalho. Em Taboada et al. (1999) é apresentada a proposta de um método para a administração de tratamentos em que as tarefas de planejamento e monitoramento consistem de um ciclo. O estado do paciente é continuamente avaliado e em função desta avaliação a terapia deve ser revisada.

Outra limitação encontra-se na incapacidade de representar formas mais complexas de relacionamento causal tanto no diagnóstico e na investigação quanto nos tratamentos.

Por exemplo, na TCN assume-se que as manifestações de duas desordens não interferem uma na outra. Não é possível representar a interferência da presença de uma desordem nas manifestações de outra desordem, ou que se duas desordens ocorrem simultaneamente pode acontecer uma manifestação não prevista em uma dessas desordens isoladamente. Similar a etapa de diagnóstico, a TCN assume que os testes laboratoriais e os tratamentos de duas desordens não interferem um no outro, isto é, não trata incompatibilidades entre desordens, exames ou tratamentos.

Os outros problemas da TCN estão relacionados com a sua implementação. A geração da base de conhecimento $KB = \{KB_a, KB_b, KB_c\}$ demanda muito tempo e atenção. Portanto, seria interessante uma ferramenta que pudesse auxiliar na geração automática da base de conhecimento. Outro ponto que poderia ser melhor tratado seria a integração bem como a interface dos três módulos em PROLOG que compõem a TCN (*bipartido_nebuloso*, *exames_nebulosos* e *tratamentos_nebulosos*) que são executados separadamente.

Conclusões

Os resultados obtidos na validação da TCN no domínio de doenças de milho foram satisfatórios tanto no escopo de diagnóstico e investigação quanto no escopo de tratamentos:

- a) no escopo de diagnóstico, a incorporação de conceitos de lógica nebulosa e teoria de decisão à TCN, minimizou uma das principais limitações da teoria TCP, que é a possibilidade de incluir um grande número de hipóteses;
- b) outra vantagem da TCN é a justificativa de respostas na solução do problema que se refere à habilidade de um sistema baseado em conhecimento em explicar como e porque chegou às conclusões como diagnose. É muito importante desenvolver métodos para justificativa de respostas, pois, estudos demonstram que, por exemplo, na medicina e na fitopatologia, há necessidade de boas explicações por sistemas de diagnóstico para aceitação pelos diagnosticadores;
- c) no escopo de investigação, pode-se destacar as funções de entropia desenvolvidas na TCN que permitem selecionar as manifestações prioritárias mesmo que não se tenha informações completas sobre elas. Esta funcionalidade que está sendo incorporada através das funções de entropia propostas, além de contribuir na seleção de manifestações prioritárias e redução de hipóteses, pode ser útil em um módulo de geração de perguntas. A habilidade de gerar boas perguntas a partir da informação disponível pode ser crucial na eficiência do problema;

- d) na literatura são encontrados muitos trabalhos na área de teoria de decisão para problemas de tomada de decisão como seleção de tratamentos. Entretanto, a abordagem abductiva integrada a conjuntos nebulosos gera um método alternativo para solução de problemas na área de tratamentos mais vantajoso porque aproveita os resultados gerados pelo módulo de diagnóstico para reduzir a complexidade de determinar um tratamento;
- e) finalmente pode-se concluir que a TCN atende os requisitos de inferência, incertezas e tomada de decisão necessários para suportar o processo de raciocínio clínico no domínio de doenças de plantas. Adicionalmente, no decorrer deste trabalho de pesquisa, a TCN também se mostrou adequada à solução dos problemas de diagnóstico, investigação e tratamentos em outros domínios de diagnóstico dinâmico, como por exemplo, no diagnóstico e controle de falhas de satélite.

Referências Bibliográficas

AGROFIT: relatório de acaricidas, bactericidas, fungicidas, inseticidas ... Brasília, DF: Ministério da Agricultura, Pecuária e Abastecimento, 2003. 145 p. Relatório técnico.

AMZI! Prolog + Logic Server: tutorials. Disponível em: <<http://www.amzi.com>>. Acesso em: 24 nov. 2004.

DUBOIS, D.; PRADE, H. **Possibility theory**: an approach to computerized processing of uncertainty. New York: Plenum Press, 1988. 263 p.

DUBOIS, D.; PRADE, H. Fuzzy relation equations and causal reasoning. **Fuzzy Sets and Systems** v. 75, n. 2, p. 119-134, Oct. 1995.

EMBRAPA. Centro Nacional de Pesquisa Tecnológica em Informática para Agricultura. **Diagnose virtual**. Disponível em: <<http://diagnose.cnptia.embrapa.br>>. Acesso em: 24 nov. 2004.

FERNANDES, F.; OLIVEIRA, E. **Principais doenças na cultura do milho**. Sete Lagoas: EMBRAPA-CNPMS; Brasília, DF: EMBRAPA-SPI, 1997. 90 p.

HENRION, M.; BREEZE, J. S.; HORVITZ, E. J. Decision analysis and expert systems. **Magazine** v. 13, n. 8, p. 64-91, 1992.

KLIR, G. J.; FOLGER, T. A. **Fuzzy sets, uncertainty, and information**. New Jersey: Prentice Hall, 1988. 355 p.

LUCAS, P. Modeling interactions for diagnosis. In: CESA'96 IMACS MULTICONFERENCE; SYMPOSIUM ON MODELLING, ANALYSIS AND SIMULATION, 1996. Lille, France. **Proceedings...** Lille, France: IMACS, 1996. p. 541-546.

MALCOLM, C. **Compendium of corn diseases**. 2. ed. St Paul: American Phytopathological Society, 1980. 105 p. (APS. Disease Compendium Series).

MASSRUHÁ, S. M. F. S. **Uma teoria de coberturas nebulosas para diagnóstico, investigação e tratamento**. 2003. 251 f. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

MORANDI, M. B.; MENEZES, C. **Monitoramento das principais doenças foliares do milho e controle químico da cercosporiose (*cercospora zae-maydis*) em função do nível de severidade da doença**. Rio Verde: Fesurv, 2002. 10 p. Relatório técnico.

PENG, Y., REGGIA, J. A. **Abductive inference models for diagnostic problem-solving**. New York: Springer Verlag, 1990. 285 p.

RAIFFA, H. **Decision analysis: introductory lectures on choices under uncertainty**. Reading: Addison-Wesley Publishing, 1970. 309 p.

RÉA-NETO, A. O raciocínio clínico - o processo de decisão diagnóstica e terapêutica. **Revista da Associação Médica Brasileira**, p. 301-311, 1998.

REIS, E., CASA, R. T. **Manual de identificação e controle de doenças de milho**. Passo Fundo: Aldeia Norte, 1996. 80 p.

SAVAGE, L. **The foundations of statistics**. New York: Dover Publications, 1972.

SHORTLIFFE, E. **Computer-based medical consultation: MYCIN**. New York: Elsevier, 1976.

TABOADA, M., LAMA, M., BARRO, S., MARIN, R., MIRA, J., PALACIOS, F. A problem-solving method for unprotocolised therapy administration task in medicine. **Artificial Intelligence in Medicine** v. 17, p. 157-180, 1999.

TUNEZ, S.; MARIN, R.; AGUILA, I.; BOSCH, A. T. M. An abductive method for solving a treatment problem. In: EUROMICRO CONFERENCE, ENGINEERING SYSTEMS AND SOFTWARE FOR THE NEXT DECADE, 24, 1998, Vasteras. **Proceedings**. Vasteras: IEEE Computer Society, 1998. v. 2, p. 737-744.

WAINER, J.; REZENDE, A. A temporal extension to the parsimonius covering theory. **Artificial Intelligence in Medicine**, v. 10, n. 3, p. 235-255, July, 1997.

WAINER, J.; SANDRI, S. A fuzzy temporal/categorical information in diagnosis. **Intelligent Temporal Information Systems in Medicine**, p. 1-19, 1998.

YAGER, R. Families of OWA operators. **Fuzzy Sets and Systems**, v. 59, n. 2, p. 125-148, Oct. 1993.



Informática Agropecuária

Ministério da Agricultura,
Pecuária e Abastecimento

