

MODELOS COMPUTACIONAIS FUZZY E LINEARES PARA AVALIAÇÃO DE DESEMPENHO

FUZZY AND LINEAR COMPUTATIONAL MODELS FOR PERFORMANCE EVALUATION

MODELOS COMPUTACIONALES FUZZY Y LINEALES PARA EVALUACIÓN DE DESEMPEÑO

Mara Marly Gomes Barreto¹

RESUMO: Esse trabalho discute a complexidade de desenvolvimento de modelos computacionais lineares e não lineares, estes com base na lógica fuzzy, para avaliação laboral. É desenvolvido e testado, em simulação, um conjunto de modelos que consideram o desempenho de colaboradores ou equipes no alcance de metas organizacionais. Como entrada, estão indicadores financeiros, de satisfação de clientes, de aprendizado e de capacidade de aceitar críticas. Como saída, um grau de recompensa devida pelo desempenho alcançado. Do ponto de vista de avaliação e saída de dados, os modelos lineares e os modelos fuzzy se mostram adequados. No entanto, do ponto de vista de desenvolvimento de tais modelos, que pressupõe uma abordagem interdisciplinar, os modelos não lineares baseados na lógica fuzzy se mostram mais adequados.

Palavras-Chave: Avaliação de Desempenho, Sistemas de Apoio à Decisão, Representação de Conhecimento, Sistemas Fuzzy.

ABSTRACT: This paper discusses the complexity of the development of linear and non-linear computational models, the latter based on fuzzy logic, for work performance evaluation. We develop and test, through simulation, a set of models that consider the performance of team members or teams in achieving organizational goals. As input, we have financial indicators, indicators of customer satisfaction, of learning and of capacity for accepting criticism. As output, a degree of the reward for the performance that was achieved. From the point of view of evaluation and output, both linear models and fuzzy models prove to be adequate. Nevertheless, from the point of view of the development of such models, which presupposes an interdisciplinary approach, non-linear models based on fuzzy logic prove to be more adequate.

Keywords: Performance Evaluation, Decision Support Systems, Knowledge Representation, Fuzzy Systems.

¹ Professora (DE) do Curso de Engenharia de Gestão e Produção e do Bacharelado em Ciência e Tecnologia. Pós-doutorado em Lógica e Teoria da Ciência - Universidade de São Paulo (USP), Instituto de Estudos Avançados (IEA), 2005. Mestrado em Engenharia de Produção - Universidade Federal do Rio de Janeiro (UFRJ), Coordenação dos Programas de Pós-Graduação em Engenharia (COPPE), 1997. Doutorado em Engenharia Civil com Ênfase em Sistemas Computacionais - Universidade Federal do Rio de Janeiro (UFRJ), Coordenação dos Programas de Pós-Graduação em Engenharia (COPPE), 1999. Graduação em Filosofia - Universidade Federal do Rio de Janeiro (UFRJ), Instituto de Filosofia e Ciências Sociais (IFCS), 1987. E-mail: mmgbarreto@gmail.com

RESUMEN: Este trabajo discute la complejidad del desarrollo de modelos computacionales lineales y no lineales, los últimos basados en la lógica fuzzy, para evaluación laboral. Se desarrolla y prueba, en simulación, un conjunto de modelos que consideran el desempeño de colaboradores o equipos en el logro de objetivos organizacionales. Como entrada, se proponen indicadores financieros, de satisfacción de los clientes, de aprendizaje y de capacidad para aceptar críticas. Como salida, un grado de recompensa debida por el desempeño alcanzado. Desde el punto de vista de la evaluación y salida de datos, los modelos lineales y los modelos fuzzy demuestran ser adecuados. Sin embargo, desde el punto de vista del desarrollo de tales modelos, que presuponen un enfoque interdisciplinar, los modelos no lineales basados en la lógica fuzzy demuestran ser más adecuados.

Palabras Clave: Evaluación de desempeño, Sistemas de soporte a las decisiones, Representación de conocimiento, Sistemas fuzzy.

INTRODUÇÃO

Um dos principais problemas que se percebe na gestão de desempenho é o controle das atividades. No ciclo de planejamento onde ocorrem os processos de planejamento, de execução e de controle existem muitos desafios, em cada etapa específica, que devem ser vencidos para que se obtenha o resultado esperado descrito em objetivos e metas (MAXIMIANO ACA, 2011). Desde a definição de objetivos, da definição de estratégias e recursos necessários até a medida de desempenho deve haver foco na obtenção de resultados, com o menor desperdício possível. Nesse contexto, é fundamental que os resultados alcançados na realização de tarefas ou atividades, entre outras coisas, possam ser mensurados. Somente com resultados de desempenho claros é que se pode tomar decisões acertadas, oferecendo incentivos ou recompensas ou aplicando processos corretivos que reorganizem ou mantenham o alinhamento de ações com foco no resultado esperado. Esse princípio se aplica a todas as etapas do controle, inclusive quando diz respeito à avaliação de atividade humana (MAXIMIANO ACA, 2011).

A medida de desempenho pressupõe, entre outras coisas, a definição de parâmetros, indicadores e meios de controle, que deve ser feita desde o estabelecimento de objetivos. Ou seja, todo processo de controle em gestão deve ter seu foco nos resultados que se quer alcançar (CHIAVENATO I, 2014). A interferência humana na busca desses objetivos é fundamental. Quando se definem as atividades a serem realizadas na busca de objetivos e metas, se diz o que deve ser feito e como deve ser feito. E o controle dessa etapa é exatamente saber se o que deve ser feito está sendo feito da forma como deve ser feito. A realização de tarefas e o alcance de metas por pessoas

constitui um movimento complexo e muitas vezes difícil de ser aferido. Quanto mais se consegue quantificar ou formalizar os parâmetros e indicadores definidos, parece se tornar mais fácil objetivar qualquer avaliação (CHIAVENATO I, 2014).

Kaplan RS e Norton DP (1992) propuseram que as medidas de desempenho de negócios sejam feitas além da perspectiva financeira, incluindo nelas as perspectivas de satisfação de clientes, de processos internos e de capacidade de aprendizado e crescimento através de um *Balanced Scorecard* (BSC). Segundo Maximiano ACA (2011) a empresa que adota essa metodologia de avaliação e a considera uma estratégia, deve implantá-la desde seu nível estratégico até seus níveis administrativos e operacionais e, portanto, nesse processo deve incluir a avaliação de colaboradores ou equipes, uma vez que tais ciclos de planejamento possuem em suas bases, indivíduos. Para Kaplan RS e Norton DP (1996) o *Balanced Scorecard*, constitui assim, um método de gestão de mudança, sempre em busca do alcance de objetivos e metas. Tal método permanece ainda presente na literatura de administração e gestão (MAXIMIANO ACA, 2011).

Nesse contexto, quando é necessário avaliar uma grande quantidade de informações, que muitas vezes são muito complexas, há a necessidade de apoio sistemático e computacional para auxílio à tomada de decisão (OLIVEIRA JF, 2007) e (TURBAN E e RAINER Jr, 2007). Os sistemas computacionais de auxílio à decisão possuem sempre um modelo lógico estrutural, que define seu escopo. Por outro lado, eles representam modelos de raciocínio humano e, sendo assim, essa estrutura lógica pode refletir ou limitar a representação de informações e de conhecimento humano em ambiente computacional, dependendo da ferramenta utilizada para seu desenvolvimento (ZADEH LA 1965; BARRETO MMG,1999).

Fazer uma escolha inadequada do método lógico de formalização ou representação de conhecimento para o desenvolvimento de sistemas de apoio à decisão, pode comprometer de forma definitiva a apresentação de sugestões dadas ao usuário final e, portanto, a escolha de caminhos a seguir em suas tomadas de decisão. Ou, por outro lado, pode dificultar muito o desenvolvimento interdisciplinar do sistema, como será comentado posteriormente. No caso de tomadas de decisão empresariais, escolhas inadequadas podem significar um prejuízo importante e muitas vezes de difícil recuperação.

O objetivo desse trabalho é mostrar uma comparação entre modelos computacionais lineares e não lineares, estes baseados na lógica fuzzy, para auxílio à decisão sobre o oferecimento de recompensas por desempenho de colaboradores ou equipes, no alcance de metas no contexto empresarial. São avaliados os métodos de construção dos modelos e os tipos de resultados obtidos. Os modelos apresentados são simulações, que constituem “o processo de projetar um modelo computacional de um sistema real e produzir experimentos com o propósito de compreender seu comportamento e/ou avaliar estratégias para sua operação. (...)” (PEGDEN et al., 1991 apud GOMES LFAM e GOMES CFS., 2019, p. 313). Já os parâmetros utilizados são baseados em Maximiano ACA (2011, 2014) e Chiavenato I (2014).

MÉTODOS

Para realizar o objetivo do trabalho, são inicialmente considerados parâmetros e indicadores estabelecidos por para a avaliação de desempenho e subsequentes tomadas de decisões acerca do oferecimento de recompensas em função do alcance de metas estabelecidas em Chiavenato I (2014) e Gomes LFAM e Gomes CFS (2019). Posteriormente são considerados parâmetros mais complexos para avaliação de desempenho e oferecimento de recompensas, baseados no Balanced Scorecard (BSC) (KAPLAN RS e NORTON DP, 1992). As estruturas de raciocínio propostas e a construção dos modelos são baseadas em indicadores de desempenho propostos por Maximiano (2011), Chiavenato I (2014) e Kaplan RS e Norton DP (1992).

Essas estruturas são compostas por regras lógicas implicativas, como mostradas por exemplo em Mortari CA (2001), contendo conjunções, disjunções e implicações, considerando como antecedentes esses indicadores de desempenho e como consequentes, as informações contidas na Figura 16.6 apresentada por Maximiano ACA (2011, p. 330) que orienta a tomada de decisão sobre o que fazer diante do alcance ou não e da superação de metas propostas.

Com base nessas regras são desenvolvidos dois tipos de modelos computacionais de representação de conhecimento, implementáveis no Matrix Laboratory (MATLAB) (2021): um linear e outro não linear, baseado na lógica fuzzy proposta e desenvolvida por Zadeh LA (1965,1996) e por Zadeh LA et al. (2016). São apresentados quatro exemplos, em simulação, de modelos computacionais lineares

com escala crescente de complexificação do raciocínio a ser formalizado, implementáveis no ambiente computacional Matrix Laboratory (MATLAB) (2021). Esses modelos são implementados e testados.

Em seguida são desenvolvidas extensões dos modelos acima, também implementáveis no ambiente computacional do Matlab Fuzzy Logic Toolbox (2021) que constitui um módulo complementar do Matrix Laboratory (MATLAB) (2021). São propostos dois exemplos, em simulação, de modelos computacionais não lineares, baseados na lógica fuzzy de Zadeh LA (1965), ambos com complexidade igual e crescente, com relação aos modelos lineares, do ponto de vista dos indicadores e dos critérios consideradas em cada caso. A última e mais complexa, é baseada no Balanced Scorecard (BSC) proposto por Kaplan RS e Norton DP (1992) e consideram as perspectivas financeira, de satisfação do cliente, de aprendizado e de aceitação de críticas e *feedback*.

Finalmente, os modelos lineares e não lineares são testados e os resultados apresentados são comparados do ponto de vista de sua construção lógica e do ponto de vista de sua capacidade de representar estruturas lógicas de avaliação de desempenho e atribuição de recompensas.

MODELOS COMPUTACIONAIS PARA AVALIAÇÃO DE DESEMPENHO

Os modelos computacionais apresentados tanto lineares quanto não lineares, estes baseados na lógica fuzzy, foram desenvolvidos para o Matrix Laboratory (MATLAB) (2021) e para o Matlab Fuzzy Logic Toolbox (2021), respectivamente. Todos os modelos foram testados, em simulações, considerando valores hipotéticos, atribuídos ao desempenho de colaboradores com relação ao alcance de metas.

Indicadores de desempenho

Segundo Chiavenato I (2014, p. 502), desempenho pode ser entendido como “(...) o comportamento ou meios instrumentais que se pretende pôr em prática” para alcançar os objetivos ou resultados, que “(...) são os resultados específicos que se pretende alcançar em um determinado período de tempo” (Ibid., p.221).

A avaliação de desempenho é realizada no processo de controle, que é a etapa do ciclo de planejamento onde se verifica se as ações e as atividades realizadas

estão focadas no cumprimento das metas. O processo de controle possui as seguintes etapas: definição de padrões de controle, aquisição de informações sobre resultados alcançados, comparação de padrões de controle com os resultados alcançados com subsequentes tomadas de decisões que consideram o oferecimento de recompensas ou a determinação de ações corretivas, se for o caso (MAXIMIANO ACA, 2011).

Regras lógicas

O modelo lógico de apoio à decisão deve, portanto, possuir essas etapas. Inicialmente são estabelecidos os padrões de controle, alinhados sempre com os objetivos e metas, de onde se seguem os indicadores de desempenho. Em seguida esses padrões de controle devem ser relacionados e devem implicar em uma classificação de desempenho e nas ações a serem realizadas em cada caso. Ao utilizar o modelo, o gestor que tem como objetivo avaliar o desempenho de seus colaboradores, deve dar uma pontuação para cada item avaliado. O modelo lógico compara os resultados obtidos com os parâmetros estabelecidos, classifica o desempenho do colaborador e sugere ao gestor as atitudes a serem tomadas no que diz respeito apenas, nesses casos, ao oferecimento de recompensas pelo desempenho alcançado.

As regras possuem a estrutura 'Se p então q', onde p é o antecedente e q é o consequente da regra. Os antecedentes das regras representam as perspectivas observadas na avaliação de desempenho e podem ser denotados por x_i ($i=1, \dots, p$). Cada regra representa o que se espera de saída a partir de um valor de entrada atribuído para cada perspectiva e é do tipo (Se, ..., então) (MENDEL JM, 2017) e (NEVES EP et al., 2019). Abaixo, no próximo parágrafo, são estabelecidas relações entre resultados, metas, desempenho e ações a serem tomadas pelo gestor, de acordo com o desempenho dos colaboradores ou equipes avaliados. Essas relações são baseadas em Maximiano ACA, 2011, p. 330, Figura 16.6. As relações estabelecidas são as seguintes e tem o formato das regras lógicas como estabelecidas em Mendel JM (2017):

Se o resultado é igual ao esperado (atinge a meta) então o desempenho é satisfatório e nesse caso, uma recompensa é devida. Se o resultado é baixo do esperado (não atinge a meta) então o desempenho é insatisfatório e então nesse caso, uma ação corretiva é devida, que pode ser a aplicação de mais recursos ou a redução da meta. Nesse caso, um incentivo pode ser dado ou não, dependendo da política empresarial

de incentivos aos colaboradores ou equipes. Se o resultado é acima do esperado (supera a meta) então o desempenho é excelente e nesse caso uma recompensa é devida e pode-se definir metas mais ambiciosas.

O raciocínio acima pode ser simplificado, por razões de brevidade, para as regras lógicas a seguir. R_1 (se a meta é atingida então o desempenho é satisfatório); R_2 (se a meta não é atingida então o desempenho é insatisfatório);

R_3 (se a meta é superada então o desempenho é excelente). Ou ainda: R_4 (se o desempenho é satisfatório então a recompensa é devida); R_5 (se o desempenho é insatisfatório então pode haver ou não haver uma recompensa) e R_6 (se o desempenho é excelente então a recompensa é devida). Nos modelos seguintes as três últimas regras acima serão consideradas. Ou seja, somente a relação entre desempenho alcançado e recompensa devida será considerada.

MODELOS COMPUTACIONAIS LINEARES

Considere-se também, hipoteticamente, em uma interpretação extensiva das regras consideradas, que todos os colaboradores recebem uma gratificação por desempenho pessoal, à medida em que alcançam as metas relacionadas aos interesses financeiros da empresa e que essa gratificação corresponde a uma porcentagem de seu salário. Em sua avaliação, um valor de 0 a 10 será atribuído ao seu desempenho com relação ao alcance das metas financeiras, onde 10 corresponde à superação da meta. A recompensa correspondente varia de 1 a 20% de seu salário. Deixe-se de lado, por razões de simplificação, a questão da atitude com relação ao aumento e à diminuição das metas e mesmo o maior investimento que se poderia fazer com relação a elas. Os exemplos apresentados terão foco no desempenho e na recompensa devida. O primeiro modelo computacional linear, Modelo_{linear1}, ilustra esse caso:

```
financeiro = 0:.5:10;
recompensa = (.10/20)*financeiro+0.01;
plot(financeiro,recompensa)
xlabel('financeiro')
ylabel('recompensa')
ylim([0.01 0.20])
```

Onde o desempenho financeiro determina o valor da recompensa a ser recebida. Nesse caso somente as metas financeiras são consideradas. A Figura 1, a seguir, mostra a relação entre o desempenho financeiro obtido ($x=7.0$) e a recompensa que será devida

($y=0,115$) ou seja, ao ser atribuído o valor 7.0 para o desempenho financeiro, a recompensa devida será de 11,5% de seu salário. O que, em uma escala de 0 a 20% representa um valor médio de recompensa.

Uma empresa que considere essa escala de recompensa muito alta, pode baixar seu valor máximo para 15%. Mas fixar um valor mínimo de 5% de gratificação sobre o salário, para incentivar seus colaboradores. E uma empresa que considere ainda que apenas resultados financeiros não são suficientes para avaliar os colaboradores, pode incluir outros quesitos de avaliação, como por exemplo o índice de satisfação de clientes de cada colaborador. Com essas três modificações, tem-se o segundo modelo computacional, Modelo_{linear2}:

```
financeiro = 0:.5:10;
cliente = 0:.5:10;
[F,C] = meshgrid(cliente,financeiro);
recompensa = (0.10/20).*(F+C)+0.05;
surf(F,C,recompensa)
xlabel('Financeiro');
ylabel('Cliente');
zlabel('Recompensa')
```

Onde o resultado financeiro e o índice de satisfação de clientes são avaliados em uma escala de 0 a 10 cada um, e a recompensa é o valor corresponde à 10% da soma desses dois valores, mais 5%. A Figura 1 mostra a relação entre o desempenho financeiro obtido ($X=7,5$), a satisfação de clientes ($Y=7,0$) e a recompensa que será devida ($Z=0,1225$) ou seja, ao serem atribuídos os valores 7.5 para o desempenho e 7.0 para a satisfação de clientes a recompensa devida será de 12,25% de seu salário. O que, em uma escala de 0 a 15% representa um valor alto.

Em uma empresa que considere importante os índices de satisfação de clientes, mas considere que os resultados financeiros devem possuir um peso maior na avaliação de desempenho, pode-se ter, por exemplo, o seguinte terceiro modelo computacional linear, Modelo_{linear3}:

```
financeiro = 0:.5:10;
cliente = 0:.5:10;
[F,C] = meshgrid(cliente,financeiro);
finanRatio = 0.85;
recompensa = finanRatio*(0.10/10*F+0.05) + ...
(1-finanRatio)*(0.10/10*C+0.05);
surf(F,C,recompensa)
xlabel('Financeiro')
ylabel('Cliente')
zlabel('Recompensa')
```

Onde os parâmetros de avaliação são os mesmos do modelo anterior, mas, em uma escala de 0 a 100 %, a avaliação dos resultados financeiros terá o peso de 85% e o valor da avaliação dos resultados relacionados à satisfação de clientes terá o peso de 15% no cálculo da recompensa. A Figura 1 mostra a relação entre o desempenho financeiro obtido ($X=5,0$), a satisfação de clientes ($Y=8,0$) e a recompensa que será devida ($Z=0,1045$) ou seja, ao serem atribuídos os valores 5.0 para o desempenho financeiro e 8.0 para a satisfação de clientes a recompensa devida será de 10,45% de seu salário. O que, em uma escala de 0 a 15%, representa um valor médio.

Um método de avaliação de desempenho que privilegie o estímulo constante aos colaboradores pode considerar que todos, em princípio, podem receber uma recompensa básica de 15% de seu salário. Mas que ao se afastar muito das metas financeiras e de satisfação de clientes, declinando delas ou as superando, esse colaborador deve ter sua recompensa acrescida ou diminuída. E nesses cálculos devem ser considerados: em uma escala de 0 a 100, o peso de 80% para a avaliação financeira e de 20% para a avaliação da satisfação de clientes. O modelo computacional abaixo satisfaz essas condições: Nesse caso, as a avaliação para o desempenho financeiro e para o desempenho com relação à satisfação de clientes é medido em uma escala de 0 a 10. O quarto modelo computacional linear, Modelo_{linear4}, ilustra esse caso.

```

financeiro = 0:.5:10;
cliente = 0:.5:10;
ylabel('cliente')
xlabel('recompensa')
finanRatio = 0.8;
recompensa = zeros(size(F));
recompensa(F<2) = ((0.10/2)*F(F<2)+0.05)*finanRatio + ...
(1-finanRatio)*(0.15/10*C(F<2)+0.05);
recompensa(F>=2 & F<8) = (0.08)*finanRatio + ...
(1-finanRatio)*(0.15/10*C(F>=2 & F<8)+0.05);
recompensa(F>=8 & F<=10) = ((0.10/2)*(F(F>=8 & F<=10)-8)+0.15)*finanRatio + ...
(1-finanRatio)*(0.15/10*C(F>=8 & F<=10)+0.05);
surf(F,C,recompensa)
xlabel('Financeiro')
ylabel('Cliente')
zlabel('Recompensa')

```

onde: se o desempenho final for menor que 2.0 ele é baixo e, portanto, o colaborador terá a sua recompensa decrescida, de acordo com sua avaliação e será menor do que 15% de seu salário; se o desempenho final estiver entre 2.0 e 8.0, sua recompensa será de 15% de seu salário; e se for maior do que 8.0, terá sua recompensa

aumentada, de acordo com sua avaliação e será maior do que 15%. A Figura 1 abaixo mostra a representação gráfica para os quatro modelos lineares desenvolvidos e mostrados acima:

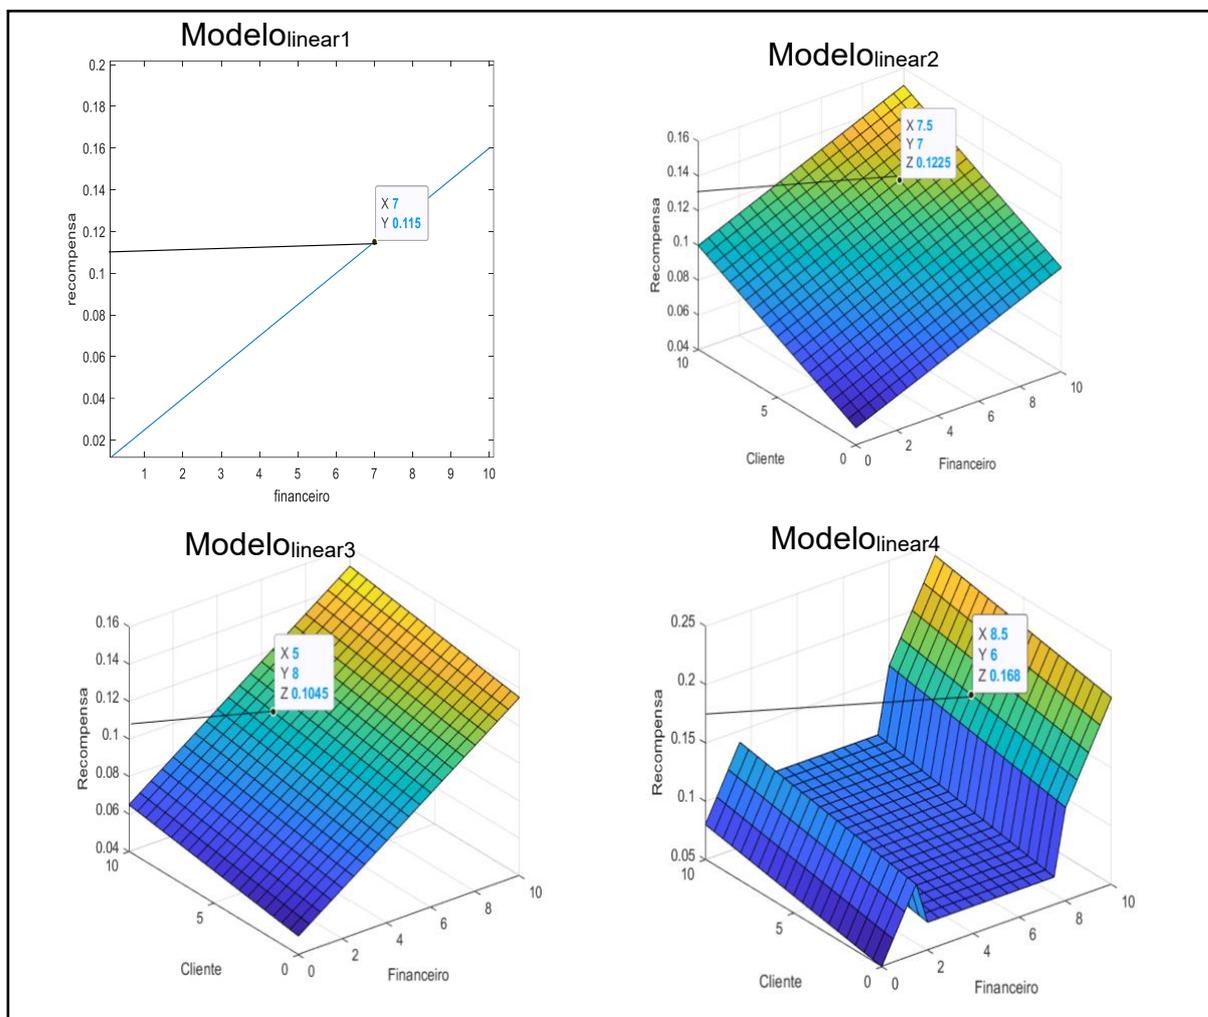


Figura 1: Entradas e saídas para os modelos lineares.

Fonte: BARRETO MMG, (2022).

MODELOS COMPUTACIONAIS NÃO LINEARES BASEADOS NA LÓGICA FUZZY

Nos modelos não lineares baseados na lógica fuzzy pode-se fazer uma interpretação extensiva das regras₄ a 6 apresentadas anteriormente, da seguinte maneira:

Considera-se os termos de entrada ‘financeiro’ e ‘cliente’ e o termo de saída ‘recompensa’, deixando aqui também, por razões de simplificação a questão relativa ao

aumento ou diminuição das metas ou o maior investimento que se poderia fazer para seu alcance. Ou seja, nesse modelo serão considerados o desempenho financeiro e o desempenho com relação à satisfação de clientes para a obtenção ou não de uma recompensa.

Assim ‘financeiro’, ‘cliente’ e ‘recompensa’, no primeiro modelo fuzzy apresentado a seguir, são consideradas variáveis linguísticas, como em Zadeh LA (1975), onde ‘financeiro’ e ‘cliente’ são variáveis de entrada e ‘recompensa’ a variável de saída. Para cada variável linguística são relacionadas conjuntos fuzzy e definidas funções de pertinência (NICOLETT MC e CAMARGO HA, 2011) e (NEVES EP et al., 2019). Essas funções de pertinência são relacionadas a parâmetros que representam os possíveis valores obtidos para o desempenho, expressos pelas variáveis de entrada. Os valores obtidos para as variáveis de entrada são relacionados a valores definidos para a variável de saída (MAMDANI EH e ASSILIAN S, 1975) e (ZADEH LA e ALIEV RA, 2018).

Para as variáveis ‘financeiro’ e ‘cliente’ são definidas as funções de pertinência ‘insuficiente’, ‘bom’ e ‘excelente’. Para a variável ‘recompensa’ são definidas as funções de pertinência ‘baixa’, ‘média’ e ‘alta’. Tem-se então a parte inicial do modelo fuzzy implementável no Matrix Laboratory (MATLAB), (2021), denominado ‘Desempenho’ e que corresponde ao Modelo_{fuzzyi}:

```

fis = mamfis('Name','Desempenho');
fis.Inputs(1) = fisvar;
fis.Inputs(1).Name = "financeiro";
fis.Inputs(1).Range = [0 10];
fis.Inputs(1).MembershipFunctions(1) = fismf;
fis.Inputs(1).MembershipFunctions(1).Name = "insuficiente";
fis.Inputs(1).MembershipFunctions(1).Type= "gaussmf";
fis.Inputs(1).MembershipFunctions(1).Parameters = [1.5 0];
fis.Inputs(1).MembershipFunctions(2) = fismf;
fis.Inputs(1).MembershipFunctions(2).Name = "bom";
fis.Inputs(1).MembershipFunctions(2).Type = "gaussmf";
fis.Inputs(1).MembershipFunctions(2).Parameters = [1.5 6];
fis.Inputs(1).MembershipFunctions(3) = fismf;
fis.Inputs(1).MembershipFunctions(3).Name = "excelente";
fis.Inputs(1).MembershipFunctions(3).Type = "gaussmf";
fis.Inputs(1).MembershipFunctions(3).Parameters = [1.5 10];
fis.Inputs(2) = fisvar;
fis.Inputs(2).MembershipFunctions(3).Parameters = [1.5 10];
...análogo para a variável 'cliente'...
fis.Outputs(1) = fisvar([2 15],'Name','recompensa");
mfi = fismf("trimf",[2 4 6],'Name','baixa");

```

```
mf2 = fismf("trimf",[6 8 10],'Name',"média");
mf3 = fismf("trimf",[10 12.5 15],'Name',"alta");
fis.Outputs(i).MembershipFunctions = [mf1 mf2 mf3];
```

...

Note-se que para cada variável é definido um escopo e para cada função de pertinência são estabelecidos subconjuntos de valores dentro dos limites desse escopo.

Definidas as variáveis e suas respectivas funções de pertinência, tem-se assim, as regras lógicas que são baseadas no conhecimento correspondente às políticas da organização com relação a recompensas oferecidas, compatíveis com o alcance de metas. Tem-se então as regras:

Regra_{fuzzy1}: (se financeiro é excelente e cliente é excelente então recompensa é alta); Regra_{fuzzy2}: (se financeiro é excelente cliente é insuficiente então recompensa é média) e Regra_{fuzzy3}: (se financeiro é bom e cliente é insuficiente então recompensa é baixa). A estrutura geral dessas regras é “(...) IF a esta’ A_i THEN b esta’ B_i , onde A_i e B_i são conjuntos fuzzy que representam termos linguísticos das variáveis de entrada e saída, respectivamente” (NEVES EP et al., 2019). Essas regras correspondem à parte seguinte e última do modelo_{fuzzy1} acima:

```
rule1 = fisrule([3 3 1 1],2);
rule2 = fisrule([3 1 2 1],2);
rule3 = fisrule([2 3 2 1],2);
rules = [rule1 rule2 rule3];
rules = update(rules,fis);
fis.Rules = rules;
```

(Sobre a representação numérica das regras lógicas, ver Mathworks Helpcenter (2022)).

A sequência acima mostra a estrutura geral do Modelo_{fuzzy1}. O modelo se chama ‘Desempenho’, sua estrutura de raciocínio é do tipo Mamdani (1975), como desenvolvido em Lilly JH (2011) e em Mathworks Helpcenter (2022), entre outros. O Modelo_{fuzzy1} possui duas variáveis de entrada, cada uma delas com três funções de pertinência gaussianas, uma variável de saída com três funções de pertinência triangulares como mostrado por exemplo em Zadeh LA e Aliev RA (2018) e três regras lógicas.

O modelo apresentado a seguir é baseado no *Balanced Scorecard* (BSC) proposto por Kaplan RS e Norton DP (1992) e tem assim, o acréscimo de duas variáveis linguísticas ‘aprendizado’ e ‘crítica’. A recompensa a ser dada é baseada nas

perspectivas financeira, de satisfação de clientes, de aprendizado e da capacidade de aceitar críticas e *feedback*, o que se considera, nesse contexto, fundamental para a revisão e a possível modificação dos processos internos da empresa.

Para as variáveis ‘financeiro’ e ‘cliente’ são definidas as funções de pertinência ‘insuficiente’, ‘bom’ e excelente’. Para a variável ‘aprendizado’ são definidas as funções de pertinência ‘pouco’, ‘médio’ e muito. Para a variável ‘crítica’ são definidas as funções de pertinência ‘baixa’, regular’ e ‘boa’. Para a variável ‘recompensa’ são definidas as funções de pertinência ‘baixa’, ‘média’ e ‘alta’. Tem-se, então, os passos iniciais do Modelo_{fuzzy2} igualmente implementável no Matrix Laboratory (MATLAB) (2021), denominado ‘DesempenhoS’, em princípio análogo ao Modelo_{fuzzy1}, mas com o acréscimo das variáveis linguísticas de entrada ‘aprendizado’ e ‘crítica’, como se pode ver abaixo:

```

fis = mamfis('Name','DesempenhoS');
...
fis.Inputs(3).Name = "aprendizado";
fis.Inputs(3).Range = [0 10];
fis.Inputs(3).MembershipFunctions(1) = fismf;
fis.Inputs(3).MembershipFunctions(1).Name = "pouco";
fis.Inputs(3).MembershipFunctions(1).Type= "gaussmf";
fis.Inputs(3).MembershipFunctions(1).Parameters = [1.5 0];
fis.Inputs(3).MembershipFunctions(2) = fismf;
fis.Inputs(3).MembershipFunctions(2).Name = "medio";
fis.Inputs(3).MembershipFunctions(2).Type = "gaussmf";
fis.Inputs(3).MembershipFunctions(2).Parameters = [1.5 7];
fis.Inputs(3).MembershipFunctions(3) = fismf;
fis.Inputs(3).MembershipFunctions(3).Name = "muito";
fis.Inputs(3).MembershipFunctions(3).Type = "gaussmf";
fis.Inputs(3).MembershipFunctions(3).Parameters = [1.5 10];
...

```

Definidas as novas variáveis e suas respectivas funções de pertinência, tem-se assim, um conjunto de regras lógicas que contém as regras anteriores e as novas regras, referentes a essas novas variáveis de entrada. Nesse sentido, o Modelo_{fuzzy2} pode ser considerado uma extensão do Modelo_{fuzzy1}. O modelo_{fuzzy2} reflete um modo de avaliação de desempenho baseado nos conceitos do Balanced Scorecard (BSC). Dessa forma, as regras acrescentadas são as seguintes:

Regra_{fuzzy4}: Se o aprendizado é muito e a capacidade de receber críticas é baixo então a recompensa é média.

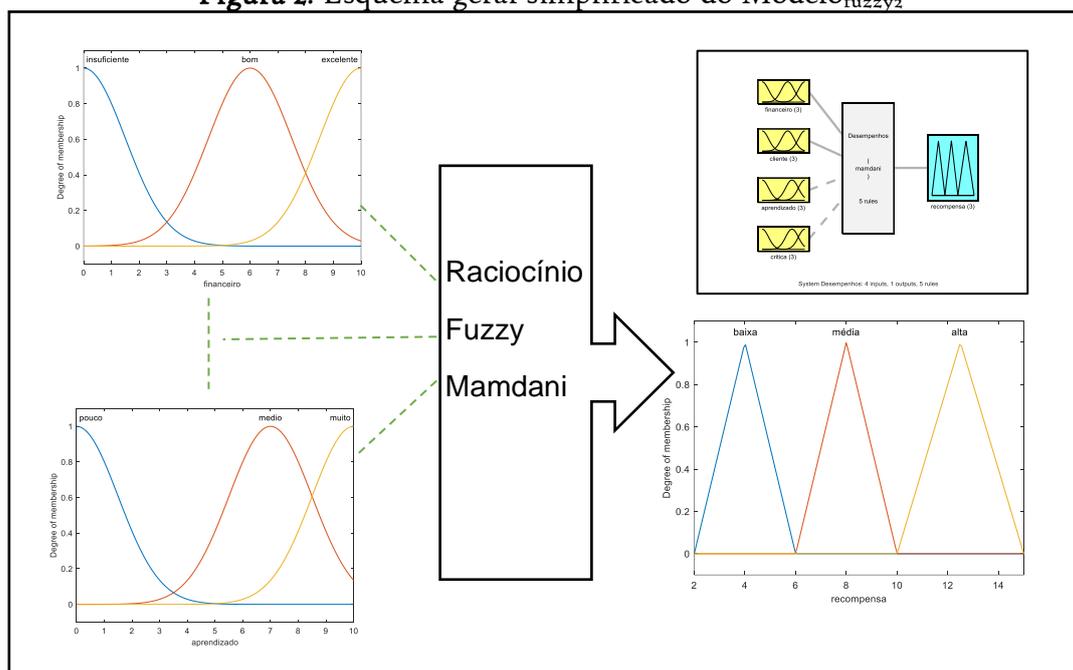
Regra_{fuzzy5}: Se o aprendizado é médio e a capacidade de receber críticas é boa então a recompensa é alta.

que correspondem à sequência do Modelo_{fuzzy 2} acima:

```
...
rule4 = fisrule([3 1 2 1 1],2);
rule5 = fisrule([2 3 3 1 1],2);
rules = [rule1 rule2 rule3 rule4 rule5];
rules = update(rules,fis);
fis.Rules = rules;
```

O modelo se chama ‘DesempenhoS’, é também do tipo Mamdani como definido em Mamdani (1975), descrito em Lilly JH (2011) e em Mathworks Helpcenter (2022). O Modelo_{fuzzy2} possui quatro variáveis de entrada, cada uma delas com três funções de pertinência gaussianas, uma variável de saída com três funções de pertinência triangulares, e cinco regras lógicas. O Modelo_{fuzzy2} constitui uma extensão do Modelo_{fuzzy1}. (ZADEH LA e ALIEV RA, 2018). A Figura 2 abaixo mostra o esquema geral simplificado do Modelo_{fuzzy2} ‘DesempenhoS’.

Figura 2: Esquema geral simplificado do Modelo_{fuzzy2}



Fonte: BARRETO MMG, (2022).

RESULTADOS E DISCUSSÕES

Serão apresentados dois tipos de resultados distintos obtidos na comparação entre os modelos lineares e os modelos não lineares baseado na lógica fuzzy. O primeiro diz respeito à estrutura interna e ao desenvolvimento desses modelos. O segundo diz

respeito aos resultados das avaliações feitas para o desempenho de colaboradores, utilizando-se diferentes entradas de dados.

Complexidade das estruturas de desenvolvimento ou programação

Considerando-se somente a estrutura lógica dos modelos lineares apresentados anteriormente, observa-se uma crescente complexificação das funções à medida em que o modelo se complexifica em função do conhecimento que se quer representar.

Tabela 1: Modelos lineares e fuzzy, variáveis e funções.

Modelos Lineares	Variáveis de Entrada e Parâmetros	Variáveis de Saída e Parâmetros	Funções
Modelo_{linear1}	financeiro = [0:5:10]	Recompensa = [0.01 0.20]	recompensa = (.15/10)*financeiro+0.01;
Modelo_{linear2}	financeiro = [0:5:10] cliente = [0:5:10]	Recompensa = [0.01 0.15]	[F,C] = meshgrid(cliente,financeiro); recompensa = (0.10/20).*(F+C)+0.05;
Modelo_{linear3}	financeiro = [0:5:10] cliente = [0:5:10]	Recompensa = [0.01 0.15]	[F,C] = meshgrid(cliente,financeiro); finanRatio = 0.85; recompensa = finanRatio*(0.10/10*F+0.05) + ... (1- finanRatio)*(0.10/10*C+0.05)
Modelo_{linear4}	financeiro = [0:5:10]; cliente = 0:5:10;	Recompensa = [0.01 0.20]	finanRatio = 0.8; recompensa = zeros(size(F)); recompensa(F<2) = ((0.10/2)*F(F<2)+0.05)*finanRatio + ... (1- finanRatio)*(0.15/10*C(F<2)+0.05); recompensa(F>=2 & F<8) = (0.08)*finanRatio + ... (1-finanRatio)*(0.15/10*C(F>=2 & F<8)+0.05); recompensa(F>=8 & F<=10) = ((0.10/2)*(F(F>=8 & F<=10)- 8)+0.15)*finanRatio + ... (1-finanRatio)*(0.15/10*C(F>=8 & F<=10)+0.05)
Modelos_{fuzzy}	Regras Lógicas		
Modelo_{fuzzy1}	Regra _{fuzzy1} : (se financeiro é excelente e cliente é excelente então recompensa é alta). Regra _{fuzzy2} : (se financeiro é excelente cliente é insuficiente então recompensa é média). Regra _{fuzzy3} : (e financeiro é bom e cliente é insuficiente então recompensa é baixa).		
Modelo_{fuzzy2} + Modelo_{fuzzy1}	Regra _{fuzzy4} : (se o aprendizado é muito e a capacidade de receber críticas é baixo então a recompensa é média). Regra _{fuzzy5} : (se o aprendizado é médio e a capacidade de receber críticas é boa então a recompensa é alta).		

Fonte: BARRETO MMG, 2002.

Analisando a tabela anterior, pode-se ver que no Modelo_{linear1}, a função utilizada é simples, uma vez que calcula somente a relação do desempenho financeiro com a recompensa que será devida, no caso, um acréscimo que pode chegar até 20% do valor do salário do colaborador. No Modelo_{linear2}, a recompensa será medida por uma relação entre o desempenho financeiro do colaborador e o seu desempenho mostrado pelo índice de satisfação dos clientes com relação ao seu trabalho, podendo sua recompensa atingir até 15% de seu salário. Nesse caso, a função se complexifica um pouco. No Modelo_{linear3}, para decidir sobre a recompensa que será devida ao colaborador, a relação entre seu desempenho financeiro e seu desempenho mostrado pelo índice de satisfação de clientes com relação a seu trabalho se mantém, mas com maior peso para seu desempenho financeiro. Nesse caso, a função se complexifica ainda um pouco mais. No Modelo_{linear4}, o valor da recompensa é calculado a partir de uma porcentagem básica sobre seu salário que poderá ser aumentada ou diminuída se seu desempenho for muito bom ou muito ruim.

Essa simulação, como descrita em Pegden et al. (1991 apud GOMES LFAM e GOMES CFS, 2019, p. 313), pode representar diferentes abordagens de avaliação de desempenho. De acordo com os valores da empresa, pode se dar mais ou menos ênfase a determinados critérios. O fato é que, em modelos lineares, cada vez que a abordagem se complexifica, e que o modelo de avaliação precisa ser recalibrado, é necessário escrever novas funções, cada vez também mais complexas. Considerando que a literatura aponta para avaliações de desempenho complexas, em que não sejam utilizados somente um ou dois índices para se obter conclusões a respeito do desempenho de colaboradores, como é proposto em Kaplan RS e Norton DP (1992) e desenvolvido em Maximiano (2011) e Chiavenato I (2014), cada vez mais requer-se o desenvolvimento de modelos que acompanhem essa complexidade, mas que sejam compatíveis com a interdisciplinaridade requerida para seu desenvolvimento. Como foi mostrado, nos modelos lineares a representação do conhecimento não se faz, assim, de forma intuitiva, sendo nesses casos, necessário a programação de modelos cada vez mais complexos. Isso dificulta o processo de criação interdisciplinar requerido no desenvolvimento de sistemas de apoio à decisão que têm como objetivo a estruturação de conhecimento humano. Quanto mais complexo o modelo, mais difícil sua

compreensão para aqueles profissionais que não possuem formação em programação ou métodos formais.

A construção de modelos desse tipo requer uma abordagem interdisciplinar, onde o programador deve trabalhar diretamente com os detentores do conhecimento que se quer representar, como os gestores que determinam os parâmetros a serem utilizados como balizamento, nos casos de avaliação de desempenho aqui mostrados. Quanto mais clara for a interface entre esses profissionais, mais eficientes e eficazes poderão ser os resultados, pois os modelos criados devem representar o que de fato o conhecimento em questão significa.

Já as regras lógicas estruturadas para os modelos fuzzy são mais intuitivas, como também se pode observar pela Tabela 1 acima. A complexidade do conhecimento que se quer representar não acarreta, nesse caso, a complexificação do modelo desenvolvido. Isso significa um ganho para a interação interdisciplinar requerida no desenvolvimento desse tipo de sistema de avaliação de desempenho. Nesses modelos, como foi visto, os conceitos são representados por variáveis linguísticas, como definidas em Zadeh LA (1975) e seus respectivos conjuntos fuzzy, que também são nomeados linguisticamente (NICOLETT MC e CAMARGO HA, 2011) e (NEVES EP et al., 2019). Ou seja, as variáveis e regras podem ser escritas em linguagem natural.

Como está mostrado na Tabela 1 acima, a modificação ou o acréscimo de regras é intuitivamente mais claro, não importando a complexidade do conhecimento que se queira representar. Nesse ponto, é importante observar que decorre daí que um tal sistema pode facilmente não se tornar obsoleto, pois a qualquer momento que seja necessário recalibrá-lo, pode-se acrescentar, retirar ou modificar variáveis e regras, sem necessidade de programações complexas. Essa possibilidade proporciona ao sistema um maior ciclo de vida, reduzindo gastos e desperdício de recursos para a empresa. (TURBAN E e RAINER Jr, 2007).

Saídas de dados e auxílio à tomada de decisão

Com relação às saídas de dados para cada grupo de valores de entrada, considerados nos modelos lineares e nos modelos fuzzy, tem-se o seguinte, onde para cada um dos Modelos_{lineares1-4} foi realizado um teste:

Para o Modelo_{linear1} foi atribuído, por hipótese, o valor de entrada 7.0 para a variável linguística ‘financeiro’. Para essa entrada, obteve-se o valor 0.115 para saída que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa média’ como devida. Para o Modelo_{linear2} foram atribuídos, por hipótese, o valor de entrada 7.5 para a variável linguística ‘financeiro’ e 7.0 para a variável linguística ‘cliente’. Para essas entradas, obteve-se o valor 0.1225 para saída que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa alta’ como devida. Para o Modelo_{linear3} foram atribuídos, por hipótese, o valor de entrada 5.0 para a variável linguística ‘financeiro’ e 8.0 para a variável linguística ‘cliente’. Para essas entradas, obteve-se o valor 0.1045 para saída que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa média’ como devida. Para o Modelo_{linear4} foram atribuídos, por hipótese, o valor de entrada 8.5 para a variável linguística ‘financeiro’ e 6.0 para a variável linguística ‘cliente’. Para essas entradas obteve-se o valor 0.168 para saída, que segundo o escopo e os parâmetros da variável ‘recompensa’ indica uma ‘recompensa aumentada’, ou seja além de 0.15, como devida. A Tabela 2 abaixo mostra os testes para os modelos lineares e para os modelos fuzzy.

Tabela 2: Avaliação de desempenho e recompensa com diferentes entradas para os modelos lineares e para os modelos fuzzy.

Modelos Lineares Entradas x= financeiro y= cliente	Saídas z=recompensa	Recompensa/ Parâmetros e Classificação
Modelo _{linear1} x= 7.0	z=0.115	[0.01 0.20] Média
Modelo _{linear2} X= 7.5 Y= 7.0	z=0.1225	[0.01 0.15] Alta
Modelo _{linear3} x= 5.0 y= 8.0	z=0.1045	[0.01 0.15] Média
Modelo _{linear4} x= 8.5 y= 6.0	z=0.168	[0.01 0.20] Aumentada: a partir de 0.15
Entradas Modelo _{fuzzy1} [‘financeiro’, ‘cliente’]	Saídas Modelo _{fuzzy1}	Recompensa, Parâmetros e Classificação Modelo _{fuzzy1}

$evalfis(fis,[7.5\ 7])$	ans = 10.4960	Alta [10 12.5 15]
$evalfis(fis,[5\ 8])$	ans = 8.0644	Média [6 8 10]
$evalfis(fis,[8.5\ 6])$	ans = 10.4816	Alta [10 12.5 15]
Entradas Modelo_{fuzzy2} [‘financeiro’, ‘cliente’, ‘aprendizado’, ‘crítica’]	Saídas Modelo_{fuzzy2}	Recompensa, Parâmetros e Classificação Modelo_{fuzzy2}
$evalfis(fis,[10\ 2\ 7.5\ 4])$	ans = 7.6723	Média [6 8 10]
$evalfis(fis,[5\ 3\ 9\ 6])$	ans = 3.9880	Baixa [2 4 6]
$evalfis(fis,[9\ 8.6\ 7\ 9])$	ans = 12.4987	Alta [10 12.5 15]

Fonte: BARRETO MMG, (2022).

Ainda como se pode ver pela Tabela 2 acima, para o Modelo_{fuzzy1} foram realizados os três seguintes testes, considerando, por hipótese, valores de entrada para as variáveis linguísticas ‘financeiro’ e ‘cliente’. No primeiro teste, foi atribuído à variável ‘financeiro’ o valor 7.5, e à variável ‘cliente’ foi atribuído o valor 7.0. Para essas entradas obteve-se o valor 10.4960 que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa alta’ como devida. No segundo teste, foi atribuído à variável ‘financeiro’ o valor 5.0, e à variável ‘cliente’ foi atribuído o valor 8.0. Para essas entradas obteve-se o valor 8.0644 que, segundo o escopo e os parâmetros da variável ‘recompensa,’ indica uma ‘recompensa média’ como devida. No terceiro teste, foi atribuído à variável ‘financeiro’ o valor 8,5, e foi atribuído à variável ‘cliente’ o valor 6.0. Para essas entradas obteve-se o valor 10.4816 que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa alta’ como devida.

Para o modelo modelo_{fuzzy 2} foram realizados os três seguintes testes, considerando, por hipótese, valores de entrada para as variáveis linguísticas ‘financeiro’, ‘cliente’, ‘aprendizado’ e ‘crítica’. No primeiro teste, foram atribuídos os seguintes valores: à variável ‘financeiro’ o valor 10, à variável ‘cliente’ o valor 2.0, à variável ‘aprendizado’ o valor 7.5 e à variável ‘crítica’ o valor 4.0. Para essas entradas obteve-se o valor 7.6723 que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa média’ como devida. No segundo teste, foram

atribuídos os seguintes valores: à variável ‘financeiro’ o valor 5, à variável ‘cliente’ o valor 3,0, à variável ‘aprendizado’ o valor 9,0 e à variável ‘crítica’ o valor 6,0. Para essas entradas obteve-se o valor 3,9880 que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa baixa’ como devida. No terceiro teste, foram atribuídos os seguintes valores: à variável ‘financeiro’ o valor 9,0, à variável ‘cliente’ o valor 8,6, à variável ‘aprendizado’ o valor 7,0 e à variável ‘crítica’ o valor 9,0. Para essas entradas obteve-se o valor 3,9880 que, segundo o escopo e os parâmetros da variável ‘recompensa’, indica uma ‘recompensa alta’ como devida.

Pelos testes acima pode-se verificar que tais modelos, tanto os lineares quanto os fuzzy, conseguem representar o conteúdo proposto para avaliação de desempenho. Do ponto de vista do fornecimento de resultados, os modelos se mostram equiparáveis. Ou seja, ambos são capazes de considerar aspectos complexos na avaliação de desempenho e oferecer resultados flexíveis, porém objetivos, podendo se distanciar da polaridade ‘sim’ e ‘não’ ou ‘falso’ e ‘verdadeiro’.

CONCLUSÃO

Comparando os modelos_{lineares1-4} com os modelos_{fuzzy1e2}, do ponto de vista de seu desenvolvimento, verifica-se que nos dois casos é possível representar conhecimento e implementar modelos que atendam à necessidade de auxílio à tomada de decisão sobre o desempenho de colaboradores ou equipes de trabalho em uma organização. Em ambos os casos é possível estender os modelos, partindo-se de um modelo básico, aumentando o nível de complexidade e modificando-o, de acordo com as necessidades ou critérios empresariais. Com relação aos resultados obtidos para avaliação de desempenho, ambos os sistemas são capazes de apresentar resultados flexíveis, não se limitando à polaridade ‘sim e não’. A diferença que se observa é na complexidade, e portanto, no esforço de programação exigida para o desenvolvimento de tais modelos, que pode impactar, negativamente, na interdisciplinaridade necessária ao desenvolvimento de tais modelos de apoio à decisão para avaliação de desempenho. Considerando-se que a literatura cada vez mais atualizada sempre sugere modificações e aperfeiçoamentos relacionadas à avaliação de desempenho no contexto empresarial, modelos computacionais que não possam ser facilmente atualizados,

tornam-se facilmente obsoletos, podendo significar a médio e longo prazos um prejuízo significativo para a empresa. O que leva à conclusão de que os modelos fuzzy, nesse caso, se mostram mais adequados, pois não requerem um grande esforço de programação, permitindo assim, que o maior foco seja a estruturação do conhecimento requerido.

REFERÊNCIAS

1. BARRETO MMG. Metodologia Fuzzy para a Construção de Sistemas Especialistas com Bases de Conhecimento Inconsistentes (Tese de Doutorado), Coordenação dos Programas de Pós-Graduação em Engenharia (COPPE), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1999; 137 p.
2. CHIAVENATO I. Administração nos novos tempos. Terceira edição. São Paulo: Editora Manole, 2014; 626 p.
3. GOMES LFAM, GOMES CFS. Princípios e métodos para tomada de decisão. Sexta edição. São Paulo: Editora Atlas, 2019; 341 p.
4. KAPLAN RS, NORTON DP. The Balanced Scorecard- Measures that drive performance. Harvard Business Review, 1992; January-february: 71-79.
5. KAPLAN RS, NORTON, DP. The Balanced Scorecard- Translating strategy into action. First edition. Cambridge, MA: Harvard Business Review Press, 1996; 418 p.
6. LILLY JH. Fuzzy control and identification. First Edition. New York: Wiley, 2011; 248 p.
7. MAMDANI EH, and ASSILIAN S. 'An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller'. International Journal of Man-Machine Studies, 1975; 7(1): 1-13.
8. MATHWORKS HELPCENTER. Disponível em <https://ww2.mathworks.cn/help/fuzzy/types-of-fuzzy-inference-systems.html>. Acesso em: 27/05/2022.
9. MATLAB. Guia do usuário. MathWorks, 2021.
10. Matlab Fuzzy Logic Toolbox. Guia do usuário. MathWorks, 2021.
11. MAXIMIANO ACA. Introdução à administração. Oitava edição. São Paulo: Editora Atlas, 2011; 419 p.
12. MAXIMIANO ACA. Administração de projetos. Quinta edição. São Paulo: Editora Atlas, 2014; 396.
13. MENDEL, JM. Uncertain rule-based fuzzy systems. Second edition. New York: Springer, 2018; 684 p.
14. MORTARI CA. Introdução à Lógica. Primeira edição. São Paulo: Editora Unesp, 2001; 393.
15. NEVES EP et al. Sistema baseado em regras fuzzy para avaliação da qualidade da água. Revista Eletrônica Paulista de Matemática, 2019; (14): 95-109.
16. NICOLETT MC, CAMARGO, HA. Fundamentos da Teoria de Conjuntos Fuzzy. Série Apontamentos. São Carlos: EDUFSCAR, 2011; 65 p.
17. OLIVEIRA JF. Sistemas de informação- Um enfoque gerencial, inserido no contexto empresarial e tecnológico. Quinta edição. São Paulo: Editora Érica, 2007; 336p.

18. PEGDEN CD et al. Introduction to Simulation using SIMAN. Second edition. New York: McGraw Hill, 1991; 600 p.
19. TURBAN E, RAINER Jr. Introdução a sistemas de informação- Uma abordagem gerencial, tradução de Daniel Vieira. Primeira edição. Rio de Janeiro: Editora Campus, 2007; 384 p.
20. ZADEH LA. Fuzzy sets. Information and control, 1965; 8(3): 338-353.
21. ZADEH LA. The concept of linguistic variable and its application to approximate reasoning I. Information Science, 1975; 8: 199-249.
22. ZADEH LA. Fuzzy logic = computing with words. Transactions on fuzzy systems, 1996; 4(2): 103-111.
23. ZADEH L A (Editor et al.). Recent Developments and New Direction in Soft-Computing Foundations and Applications. First edition. New York: Springer, 2016; 755 p.
24. ZADEH LA, ALIEV RA. Fuzzy logic theory and applications: part I and part II. Singapore: World Scientific Publishing Company, 2018; 610 p.