

ALGORITMOS GENÉTICOS PARA OTIMIZAÇÃO DE PARÂMETROS EM SENSORES DE CONFORTO TÉRMICO

Rodrigo Trebien (1); Nathan Mendes (2); Gustavo Henrique da Costa Oliveira (3)

(1) Pontifícia Universidade Católica do Paraná (PUCPR), Centro de Ciências Exatas e de Tecnologia, Laboratório de Sistemas Térmicos, Rua Imaculada Conceição, 1155, 80.215-901, Curitiba – PR, Tel. (41) 88033217, e-mail: rtrebien@yahoo.com.br

(2) Pontifícia Universidade Católica do Paraná (PUCPR), Centro de Ciências Exatas e de Tecnologia, Laboratório de Sistemas Térmicos, Rua Imaculada Conceição, 1155, 80.215-901, Curitiba – PR, Tel. (41) 32711322, Fax (41) 32711691, e-mail: nathan.mendes@pucpr.br

(3) Pontifícia Universidade Católica do Paraná (PUCPR), Centro de Ciências Exatas e de Tecnologia, Programa de Pós Graduação em Engenharia de Produção e Sistemas, Rua Imaculada Conceição, 1155, 80.215-901, Curitiba – PR, Tel. (41) 32711330, Fax (41) 32711333, e-mail: gustavo.oliveira@pucpr.br

RESUMO

Os sistemas de controle de equipamentos de climatização, baseados em conforto térmico em contraste com abordagens que consideram apenas temperatura e umidade, têm como objetivo proporcionar uma melhor qualidade térmica dos ambientes. Dentre os índices para conforto térmico, a abordagem de Fanger, isto é, o PMV (*Predicted Mean Vote*), tem grande destaque. Porém, a obtenção deste índice em equipamentos reais não é trivial. O primeiro motivo é a dificuldade de sensoriamento da temperatura radiante média. O segundo fato é o caráter impreciso e incerto que possui a determinação de fatores individuais como a taxa de metabolismo humano e a resistência térmica das vestimentas dos ocupantes dos ambientes. Diante destas dificuldades, ajustes e adaptações devem ser realizados e, conseqüentemente, erros sempre estarão presentes devido à estes três parâmetros. Este trabalho propõe mecanismos para obtenção de dois dos três parâmetros mais sujeitos às incertezas de medição, isto é, os fatores individuais, para que seja viável a elaboração de um sensor de PMV. Assumindo uma escala discreta para seleção dos parâmetros individuais, este trabalho propõe e apresenta a utilização de algoritmos genéticos para obtenção de valores de escala que minimize o erro de medição.

ABSTRACT

The HVAC control systems based on thermal comfort, in contrast with strategies that consider only temperature and humidity, provide advantages such as the improvement of the thermal quality of the built environment. Among the thermal comfort indices, the Fanger's model (PMV) is the most used. However the attainment of this index in real equipment is considerably difficult. The first reason is the difficulty of measuring the mean radiant temperature. Second the determination of individual parameters such as human metabolic rate and the thermal resistance of clothing which have inexact and uncertain character. Due to those difficulties, adjustments and adaptations must be carried out and, consequently errors always will occur due to these three parameters. This work considers mechanisms for obtaining two of the three parameters more sensible to measurement uncertainties, so that a PMV sensor could be viable. Assuming a discrete scale for election of the individual parameters, this work considers and presents the use of genetic algorithms for attainment of values of scale that minimizes the measurement error.

1. INTRODUÇÃO

A criação de um ambiente com conforto térmico é um importante parâmetro nos projetos de edificações. O estabelecimento de conforto térmico em edificações é a principal tarefa dos equipamentos de controle de sistemas de climatização. Como exemplo, se os ambientes de trabalho não oferecerem conforto térmico, o desempenho dos trabalhadores tende a cair (INNOVA, 2005).

Conforto térmico é um conceito de difícil definição. Durante as últimas décadas, um grande número de índices de conforto térmico foi estabelecido, voltados à análise e projeto de sistemas de climatização (ASHRAE, 1993). Porém, o mais disseminado destes índices é o PMV (*Predicted Mean Vote*) proposto em Fanger (1970). Tal índice considera variáveis ambientais e fatores individuais e, quanto mais próximo de zero for o PMV, melhor será a sensação térmica dos ocupantes. A equação de conforto térmico, derivada por Fanger, é complexa e tende a reproduzir, com um bom grau de confiabilidade, a sensação de conforto para a maioria das pessoas em ambientes.

Desta forma, verifica-se que equipamentos que utilizem o índice PMV em sua estratégia de controle, tendem a obter melhores resultados no sentido de proporcionar conforto aos integrantes do ambiente. Abordagens de controle do conforto térmico de ambientes são apresentadas em (HAMDI; LACHIVER, 1999; FREIRE, 2006; FREIRE et al., 2005; GOUDA et al., 2001).

Devido à importância que se utilize o modelo de Fanger e devido à complexidade de sua obtenção, fora de ambientes de simulação, a construção do hardware para o índice PMV deve ser investigada. O ponto fundamental na implementação deste sensor está ligado ao fato que alguns destes parâmetros possuem uma grande dificuldade em serem obtidos.

Sensores para a medição de temperatura radiante média são, em relação a sensores de temperatura ou umidade, difíceis de serem obtidos, imprecisos ou inviáveis de serem incorporados em um sistema de controle de climatização. Ademais, essa imprecisão seria corrigida se o sensor fosse localizado exatamente na mesma posição do ocupante, a cada instante de tempo, e ainda se o formato deste sensor fosse o mesmo do ocupante. Este cenário é difícil de ser reproduzido, obrigando que algum ajuste sempre tenha que ser realizado. Portanto, a temperatura radiante média, no contexto do cálculo do PMV, está entre os parâmetros mais difíceis de serem obtidos e está sujeito a grandes erros e incertezas. Em Trebien et al. (2006), avaliou-se o impacto no índice PMV, da hipótese que a temperatura radiante média seja igual à temperatura do ar. Verificou-se que em um sistema de controle que mantenha o PMV em 0, uma diferença de $\pm 3,85^{\circ}\text{C}$ entre estas temperaturas faria com que o índice real de PMV fosse $\pm 0,5$, valor este aceitável como condição de conforto (ASHRAE, 1993).

O índice de vestimentas, em um sistema real, é um parâmetro assumido constante ou determinado por um usuário que não conhece o valor de resistência térmica de sua vestimenta. Uma solução é fornecer um conjunto de opções onde, de acordo com aquela indicada pelo usuário, alimenta-se o sistema de controle de condicionamento de ar com um valor correspondente. Um número finito de opções fornecidas para um usuário que pode estar vestindo um número infinito de tipos de vestimentas faz com que um erro esteja presente no sistema. Erros também podem advir do fato que diferentes integrantes de um ambiente podem estar (ou certamente estarão) vestindo roupas diferentes, o que é em parte amenizado pelo fato que, em geral, um ambiente desempenha um determinado papel funcional (escritório, dormitório, sala de ginástica, etc.) e, portanto, as pessoas em seu interior tendem a vestir roupas parecidas no sentido proteção térmica. Porém, apesar de parecidas, as roupas não são iguais. Assim, algum nível de erro sempre estará presente e deve ser investigado.

O nível de atividade física apresenta características semelhantes ao problema descrito para o parâmetro de vestimentas, com a agravante que este parâmetro tem uma variação maior de acordo com cada integrante presente no ambiente. Além da possibilidade dos integrantes do ambiente estarem realizando atividades diferentes (o que poderia ser amenizado, pois, em geral, ambientes têm uma função única) o nível de metabolismo corpóreo dos integrantes pode variar. Assim, pode-se afirmar que este parâmetro não somente é de difícil obtenção devido à imprecisão (como ocorre com o nível de vestimenta), como é impossível de se obter de forma uniforme para um ambiente que possua mais de um ocupante.

Assim sendo, mesmo quando o índice PMV é calculado, não é possível ter certeza de quão fiel ele é em relação ao PMV real que o ambiente possui para determinado ocupante. Neste sentido, o presente

trabalho possui como foco a melhoria do processo de medição do PMV sob o ponto de vista de aspetos oriundos da dificuldade de determinação da escala dos índices de metabolismo e nível de vestimentas. Este objetivo será alcançado, se a redução das incertezas de medição dos parâmetros do modelo de Fanger, em especial dos dois parâmetros individuais, que são sujeitos à grandes erros, for tal que a combinação dos erros causados pela determinação dos seis parâmetros provoque um erro máximo de $\pm 0,5$ no índice PMV e, portanto, possibilitando o uso deste sensor proposto, em estratégias de controle de climatizadores.

Uma análise do efeito das adaptações e ajustes necessários para a obtenção dos parâmetros individuais no índice PMV é realizada em Trebien et al. (2006). Neste trabalho, verificou-se que a derivada do PMV com relação à estes parâmetros tem uma variação moderada se modificarmos os valores da temperatura e varia muito pouco para diferentes valores de umidade e velocidade do ar. Porém a grande variação é verificada, para diferentes valores do próprio parâmetro individual. Segundo esta pesquisa, erros maiores para o índice PMV ocorreram caso os erros na alimentação do sistema, com um dos parâmetros individuais, ocorram em valores menores destes parâmetros.

Assim sendo, existe um compromisso entre precisão e custo / complexidade do equipamento na escolha do número de opções a serem selecionadas pelo usuário. Por tudo isto, a utilização de um método de otimização na busca dos valores ótimos como opções para estes parâmetros é importante. Devido à complexidade que possui a equação do PMV, métodos denominados como algoritmos genéticos são adequados em situações como esta. A evolução dos valores para os parâmetros individuais é obtida, através das gerações, ficando transparente a complexidade do modelo matemático. Algumas características deste método, inspirados na genética, como a aleatoriedade da população e a presença da mutação, fazem com que o problema de mínimos locais tenda a ser diminuído. Outro aspecto é que o alto custo computacional, geralmente associado aos algoritmos genéticos, tem pouca relevância nesta aplicação, por não se tratar de uma otimização em tempo real, mas sim de um algoritmo que é usado somente uma vez.

O presente artigo está estruturado conforme apresentado a seguir. Na Seção 2, a estratégia de obtenção dos parâmetros individuais é descrita. Na Seção 3, é utilizado o algoritmo genético para a otimização dos valores das chaves seletoras dos parâmetros individuais, com os resultados apresentados nas seções 3.1 e 3.2. Finalmente, na Seção 4, o artigo é concluído. Na Tabela 1 são mostrados os parâmetros do modelo de Fanger, os respectivos símbolos e unidades de medida e os limites destes parâmetros utilizados nas análises deste artigo.

Tabela 1 – Parâmetros do modelo de Fanger, unidades e os limites adotados.

Parâmetro	Símbolo	Unidade	Limite Inferior	Limite Superior
Temperatura do ar	T_{ar}	°C	18,0	30,0
Temperatura radiante média	T_{rm}	°C	$T_{ar} - 4,0$	$T_{ar} + 4,0$
Umidade relativa	ϕ	%	30	70
Velocidade do ar	V_{ar}	m/s	0,0	0,2
Taxa de Metabolismo Humano	MET	met	0,8	3,0
Resistência térmica das vestimentas	CLO	clo	0,3	1,15

2. ESTRATÉGIA DE OBTENÇÃO DOS PARÂMETROS INDIVIDUAIS PARA O SENSOR DE PMV PROPOSTO

Como mencionado, os parâmetros individuais possuem um número finito de opções, devido a considerações como custo e complexidade na construção do sensor. Em um estudo de caso realizado por Trebien et al. (2006), verificou-se que se fossem definidas oito opções para o parâmetro MET, e estas fossem distribuídas de forma uniforme ou apenas privilegiando as atividades mais usuais, a

incerteza de medição apenas deste parâmetro, já acarretaria um erro superior a 0,5 no PMV. Neste mesmo trabalho, observou-se que, se uma escolha mais criteriosa dos oito valores fosse realizada, baseando-se na análise das derivadas do PMV com relação aos parâmetros individuais, a incerteza de medição cairia de tal forma que o PMV se encontraria em faixas aceitáveis. Porém, não basta que o erro provocado no PMV devido a um parâmetro apenas esteja em faixas aceitáveis, visto que o PMV é influenciado pela combinação dos erros dos seis parâmetros. Desta forma deve-se objetivar a redução das incertezas de medição dos dois parâmetros individuais. Esta medida possui uma importância especial, devido ao grande peso que estes parâmetros possuem no modelo de Fanger, como visto em Trebien et al. (2007).

A primeira ação é adotar como dez, o número de opções para as chaves seletoras dos parâmetros individuais. A segunda medida é otimizar a distribuição dos dez valores. Uma distribuição uniforme dos valores, dentro dos limites do parâmetro, não gera bons resultados, pelo fato que a derivada parcial do PMV com relação aos parâmetros individuais não é constante, como visto em Trebien et al. (2006). Por estes motivos, escolheu-se o uso de um método de otimização, a saber, algoritmos genéticos, para que se busque o conjunto ótimo de valores para cada um dos parâmetros individuais.

Por outro lado, a adoção de valores próximos à realidade do usuário tende a diminuir erros devido ao fato de que se a opção real não está presente no sistema, o usuário pode não escolher a opção mais próxima da real, o que geraria erros maiores ainda.

Com isto, entre a situação de escolher valores para os parâmetros individuais, comuns à realidade dos usuários, e adotar os valores obtidos pelo método de otimização, optou-se por uma situação intermediária, onde alguns dos valores serão pré-definidos, com o critério de serem os mais usuais em um ambiente sujeito ao controle. Com algumas destas opções definidas, dentre as dez de cada parâmetro, utiliza-se algoritmo genético para a busca dos demais valores, que certamente serão influenciados pelas escolhas prévias. Para o parâmetro MET foram escolhidos os valores: 0,8; 1,0; 1,2; 1,6; 2,9. As atividades que são correspondentes à estes valores podem ser vistas na Tabela 2. Apesar de se pré-determinar cinco valores, não sendo otimizados os dez, espera-se que o erro nesta estratégia, seja apenas um pouco maior que o esperado para a otimização dos dez valores. O motivo é que o algoritmo tentará, da melhor maneira possível determinar os cinco demais valores, sempre considerando os cinco pré-definidos.

Tabela 2 – Valores usuais para o parâmetro MET.

Descrição da atividade	Valor de MET
Dormindo	0,8
Descansando (sentado)	1,0
Descansando (em pé) / Atividade em escritório ou laboratório (sentado)	1,2
Aula ou apresentação (em pé)	1,6
Assistente de loja ou alguns trabalhos domésticos (parado)	2,0
Trabalho manual com ferramentas	2,2
Trabalho manual (frigorífico ou açougue)	2,4
Trabalho doméstico (lavando louças)	2,5
Trabalho doméstico (lavando ou passando roupas)	2,9
Trabalho manual (Bater em um molde com martelo pneumático)	3,0

Porém, ao se escolher as opções mais comuns do parâmetro CLO, verificou-se que a obtenção deste parâmetro possui diferenças com relação ao MET. O motivo é que o valor de CLO para o indivíduo é formado pelo somatório dos valores de CLO das roupas que o indivíduo está vestindo. Ao se oferecer opções únicas para CLO, para que o usuário escolha apenas uma delas, como ocorre para MET, ter-se-ia que oferecer opções que se referem a um conjunto de vestimentas que o usuário possa estar vestindo, como visto na Tabela 3. Neste caso, após o algoritmo de otimização encontrar os valores ótimos, ter-se-ia que formar um conjunto de vestimentas cujos valores de CLO assemelhassem ao valor encontrado pelo algoritmo. Uma grande dificuldade também seria encontrada pelos usuários, pois teriam que verificar qual opção possui o conjunto de vestimentas que se assemelha à sua realidade. As chances de erros seriam muito grandes, pois algumas peças poderiam se assemelhar mais com o conjunto de uma opção e outras peças com outro conjunto.

Tabela 3 – Valores usuais para o parâmetro CLO.

Descrição da atividade	Valor de CLO
Bermuda (sem calçado)	0,15
Saia curta + Blusa + Sapato ou Vestido curto + Sapato	0,50
Terno, Gravata e Sapato	1,00
Casaco longo de lã	1,15

Desta forma, optou-se por realizar uma forma diferente de se atribuir o valor de CLO. As dez chaves continuam presentes no sensor proposto, porém, cada uma corresponde a um tipo de roupa com o respectivo valor de CLO. O usuário seleciona todas as chaves que correspondam às peças de roupas que ele está usando. Quando a avaliação da equação de Fanger estiver sendo realizada, em tempo real, o sensor irá verificar quais opções estão selecionadas pelo usuário e, o CLO utilizado na equação do PMV, é aquele formado pelo somatório dos valores de CLO referentes às chaves selecionadas. Com este esquema, o usuário pode entrar com as opções no sensor, para que a sua vestimenta seja reproduzida exatamente como sua realidade e, ao invés de dez opções, será oferecido o número de opções referente à combinação das dez chaves, ou seja, mil e vinte e quatro opções. Portanto, esta alternativa é a opção ótima para a definição dos valores de CLO.

Se fosse adotado algo parecido para MET, com o usuário podendo selecionar mais de uma chave e assim se obter mil e vinte e quatro opções, haveria apenas uma interface de baixa qualidade no que se refere à ergonomia, pois para se obter este número de combinações, seria necessário que o usuário realizasse uma combinação binária das opções. O processo de habilitar mais de uma chave não seria intuitivo, ou seja, não facilitaria o uso do sensor proposto, como ocorre para CLO.

3. DEFINIÇÃO DOS VALORES DOS PARÂMETROS INDIVIDUAIS ATRAVÉS DO USO DE ALGORITMOS GENÉTICOS

O primeiro passo para a definição dos parâmetros individuais é a definição dos limites de valores esperados para os seis parâmetros do modelo de Fanger. Para a umidade relativa, os limites foram definidos para que não ocorra desconforto térmico, devido a este parâmetro. Estes valores e aqueles referentes aos demais parâmetros podem ser verificados na Tabela 1.

O segundo passo é a escolha de alguns valores para MET que devem obrigatoriamente estar presentes dentre os dez valores, por serem correspondentes a atividades muito importantes e usuais. Para CLO, deve-se escolher quais peças de roupas serão relacionadas a cada uma das dez chaves seletoras.

A avaliação do erro máximo que ocorre nos parâmetros individuais depende do conjunto de dez opções disponíveis para o parâmetro, do valor do próprio parâmetro individual e das cinco demais variáveis do índice PMV. Por estes motivos, a cada evolução do algoritmo genético, todos os

indivíduos da população (onde cada indivíduo é um conjunto particular de valores para as dez opções de MET) devem ser submetidos a um infinito número de combinações dos seis parâmetros do PMV, para que se avalie o maior erro quadrático presente entre todas estas combinações possíveis de ocorrer. Portanto, estará se avaliando qual o maior erro possível de ocorrer, para um determinado conjunto de opções do parâmetro individual que está sendo avaliado. Um número infinito de combinações não é possível de ser obtido. Pode-se chegar a uma aproximação deste cenário, através de um grande número de combinações. Para isto, definiu-se que 1500 combinações devem ser avaliadas, por meio do Método de Monte Carlo. Gera-se uma matriz de números aleatórios, onde cada coluna representa um dos seis parâmetros do modelo de Fanger. Cada linha representa uma diferente combinação destes parâmetros, pois todos sofrem uma variação aleatória que é realizada por uma distribuição uniforme dos valores do parâmetro, dentro dos limites vistos na Tabela 1.

O quarto passo é a construção de uma rotina que avalia, para um dado valor do parâmetro individual, qual a opção mais próxima, dentre um conjunto de dez opções, simulando uma escolha do usuário ao não encontrar a opção real. O quinto passo é a implementação de uma rotina que avalie o maior erro possível de ocorrer, considerando todas as mil e quinhentas combinações dos parâmetros do PMV, para um dado conjunto de dez opções de MET. Esta rotina utiliza a matriz de valores aleatórios obtida no segundo passo e a rotina que avalie a opção mais adequada do conjunto de opções, para um determinado valor do parâmetro individual.

O sexto passo é a configuração do algoritmo genético, como visto na Tabela 4. A probabilidade de cruzamento é o parâmetro que indica qual a probabilidade dos indivíduos desta geração se cruzar para a formação da geração seguinte. A probabilidade de mutação se refere à aptidão do algoritmo em realizar uma alteração aleatória em alguma característica de um indivíduo, a fim de criar dados novos, que fujam totalmente (aleatoriamente) da tendência de convergência do algoritmo, para que se fuja do problema dos mínimos locais. Este parâmetro não pode ser muito grande, para evitar que não haja a convergência. O tamanho da população se refere à largura da busca. Ou seja, quantos indivíduos (quantos conjuntos de dez opções) serão avaliados em cada geração, para que os mais fortes (que gerem o menor erro na avaliação da rotina desenvolvida no quinto passo) sejam escolhidos para cruzamentos e mutações. O número de gerações se refere à profundidade da busca, ou seja, quantas gerações serão empregadas na busca. Estratégia elitista se refere ao critério de se garantir ou não que o melhor valor de cada geração esteja garantido na próxima geração.

Tabela 4 - Configurações do algoritmo genético para otimização dos parâmetros individuais.

Parâmetro	Valor
Probabilidade de cruzamento (<i>crossover</i>)	80%
Probabilidade de mutação	4% a 8%
Tamanho da população	200 indivíduos
Número de gerações	100
Estratégia elitista	Sim

O sétimo passo, aplicado apenas para MET, consiste em submeter este parâmetro ao algoritmo genético configurado no sexto passo, fornecendo para o algoritmo as opções pré-definidas no segundo passo e o número de novas opções desejadas. O algoritmo buscará a cada geração, otimizar as opções variáveis do parâmetro, de forma que estes valores otimizados, juntamente com as opções pré-definidas, gerem o menor erro quadrático na rotina do quinto passo, que avalia a matriz de números aleatórios. Como resultado, o algoritmo genético retorna o conjunto de dez opções ótimas (opções pré-definidas mais as opções otimizadas) para o parâmetro MET.

O oitavo passo, também aplicado apenas para MET, é um ajuste fino dos valores obtidos pelo algoritmo, para que os valores obtidos sejam aproximados para valores que se conheça uma atividade.

Como os valores ótimos são modificados, os erros devem ser levemente aumentados, porém, reduz a probabilidade do usuário errar a opção mais próxima, pela falta de opções usuais, mantendo um valor na vizinhança daquele encontrado pelo método de minimização de erros.

3.1 Resultados para o Parâmetro MET

Para o conjunto de opções pré-definidas e fornecidas para o algoritmo genético, o conjunto de opções indicadas pelo AG foi o seguinte (0,8000 0,8932 1,0000 1,1094 1,2000 1,4046 1,6000 2,0081 2,5282 2,9000). Segundo a metodologia definida, estes valores foram ajustados, a fim de que se encontre um valor próximo e que corresponda a uma opção conhecida de MET. Os novos valores são encontrados na Tabela 5, com as respectivas atividades e a opção da chave seletora que o usuário deve escolher.

Tabela 5 – Valores ótimos para o parâmetro MET, através do uso de algoritmo genético.

Parâmetro	Valor de MET	Opção da chave seletora
Dormindo	0,8000	1
Descansando (deitado)	0,8932	2
Descansando (sentado)	1,0000	3
Serviços delicados sentados (Ex: reparador de jóias e relógios)	1,1000	4
Atividades em escritório (sentado)	1,2000	5
Dirigindo automóvel ou jogos eletrônicos	1,4000	6
Aula ou apresentação (em pé)	1,6000	7
Atividade moderada (parado) – vendedor ou trabalhos domésticos	2,0000	8
Lavando louça (Parado)	2,5000	9
Trabalho doméstico (Lavando ou passando roupas)	2,9000	10

Verifica-se que existe um grande espaço sem opções entre os valores acima de 1,6000. Se o usuário estiver realizando uma opção nestes intervalos, não irá encontrar a opção e terá que escolher uma opção próxima, com grande diferença do valor real. Porém, a otimização do algoritmo indica que um erro nesta faixa de MET pode ocorrer sem que o erro em PMV seja grande. Desta forma, o algoritmo genético priorizou a inclusão de opções para baixos valores de MET, como visto nos resultados (Tabela 5). Estes resultados estão de acordo com a análise do PMV com relação ao parâmetro MET, realizada em Trebien et al. (2006).

Com estes valores, pode-se estimar o erro quadrático máximo, considerando todas as combinações dos parâmetros do PMV, através da matriz de números aleatórios. Este erro pode ser comparado com aqueles obtidos em outras possíveis situações (Tabela 6).

Tabela 6 – Comparação dos erros obtidos para diferentes conjuntos de opções para MET.

Metodologia para definição das opções	Conjunto de opções	Erro máximo
Valores usuais (valores sugeridos na Tabela 2).	0,80; 1,00; 1,20; 1,60; 2,00; 2,20; 2,40; 2,50; 2,90; 3,00	0,7992
Divisão uniforme do intervalo de MET	0,80; 1,04; 1,28; 1,53; 1,78; 2,02; 2,27; 2,51; 2,75; 3,00	0,9236
Dez valores obtidos pelo algoritmo genético.	0,8263; 0,9135; 0,9884; 1,0752; 1,2799; 1,5511; 1,9491; 2,5375; 2,5547; 2,9035	0,3608
Uso de cinco opções pré-definidas e cinco opções obtidas pelo algoritmo genético	0,8000; 0,8932; 1,0000; 1,1000; 1,2000; 1,4000; 1,6000; 2,0000; 2,5000; 2,9000	0,3623

Como visto na Tabela 6, os maiores erros ocorrem quando não é utilizado o algoritmo de otimização, ou seja, para as estratégias de utilizar apenas valores conhecidos ou realizar uma divisão uniforme do intervalo de MET. Verifica-se que estes erros não somente são maiores como são muito superiores, o que já era esperado.

Nos dois casos onde se utilizou o método de otimização, os erros máximos foram muito menores. Os resultados indicam que a opção adotada, ou seja, fixar cinco opções e otimizar as outras cinco possui um erro apenas um pouco maior que a opção de otimizar os dez valores. O motivo é que as cinco opções pré-definidas foram bem distribuídas, pois além de se considerar as atividades mais usuais, considerou-se o comportamento do PMV com relação ao MET, realizada em Trebien et al. (2006). Para a opção de se fixar cinco opções e otimizar as outras cinco, o melhor resultado foi obtido configurando o algoritmo com a probabilidade de mutação em 4%. Para este caso, um valor baixo para mutação fez com que o algoritmo convergisse mais rapidamente. Para a opção de se otimizar os dez valores, o melhor resultado foi obtido configurando o algoritmo genético com a probabilidade de mutação de 8%. Este valor mais elevado proporcionou a melhoria dos resultados, pois possibilitou a fuga de alguns indivíduos de um valor que era um mínimo local.

3.2 Resultados para o Parâmetro CLO

As peças de vestimentas definidas para o sensor PMV, correspondentes a cada chave seletora, podem ser vistas na Tabela 7. Como existem muitas opções de vestimentas, algumas delas podem não estar inclusas na lista. Para se obter o melhor resultado, optou-se por colocar dentre as opções, tipos de vestimentas diversificados e aquelas peças que são mais usuais. Outra medida foi atribuir, para uma mesma chave seletora, varias opções de vestimenta, com o critério de que tivessem os mesmos valores de CLO e que estas não pudessem ser usadas simultaneamente. Se não fosse assim, um valor errado de CLO seria alimentado no sistema, caso o usuário estivesse vestindo duas opções presentes na mesma chave, pois ele seria induzido a somente acionar esta opção, achando que com isso o sistema esteja considerando as duas opções, quando deveria ser colocado duas vezes a opção, para que os valores fossem somados. Na Tabela 7, verifica-se que "Bermuda" e "Camisola" se encontram na opção dois. O primeiro motivo é que ambas possuem o mesmo valor de CLO e, portanto, caso o usuário esteja usando alguma destas opções, deve-se adicionar 0,15 clo no valor total de CLO do indivíduo. O segundo motivo é que o senso comum nos faz pensar que um indivíduo não estará vestindo as duas opções simultaneamente. Com esta estratégia, é como se logicamente uma chave seletora a mais fosse colocada no sistema, sem que esta fosse adicionada fisicamente. Cada chave seletora que corresponda a mais de uma vestimenta, na prática, corresponde a um acréscimo deste número de opções a mais no sistema, aumentando a possibilidade do usuário encontrar todas as opções necessárias e, consequentemente reduzindo a incerteza de medição deste parâmetro.

Tabela 7 – Valores definidos para as chaves seletoras de CLO.

Descrição da vestimenta	Valor de CLO	Chave para adicionar a peça
Calçado	0,03	1
Bermuda \ camisola	0,15	2
Calça \ Saia pesada até o joelho	0,25	3
Ceroula	0,03	4
Camisa manga curta \ camiseta	0,09	5
Camisa manga comprida \ moletom \ vestido leve	0,25	6
Sweater	0,28	7
Jaqueta	0,35	8
Sobretudo leve \ paletó \ traje ou vestido de inverno - manga comprida \ pijama - manga comprida \ robe - manga comprida	0,50	9
Sobretudo altamente isolado	1,13	10

Como mencionado anteriormente, a melhor solução foi determinar as opções sem o uso do algoritmo genético. Neste caso é praticamente impossível determinar os erros de medição para CLO. Porém, o senso comum e uma análise mais aprofundada indica que este erro será sempre menor que os erros obtidos, caso o algoritmo genético determinasse dez conjuntos de vestimentas para as dez opções de CLO. Portanto, utilizou-se o algoritmo genético para determinar as dez opções de CLO (dez conjuntos de vestimentas). Com estas opções pode-se ter uma idéia do erro que ocorreria caso o mecanismo de determinação de CLO fosse igual ao de MET. Este valor pode ser usado como um limite superior, com uma grande folga, para o erro de CLO com o mecanismo adotado para este sensor. A forma de se obter este conjunto de dez valores otimizados de CLO foi a mesma que a utilizada para a determinação das dez opções otimizadas de MET e as cinco opções otimizadas para as cinco opções pré-definidas de MET. A comparação dos erros máximos para CLO, para cada estratégia, para sua determinação, pode ser encontrada na Tabela 8.

Tabela 8 – Erros obtidos para diferentes maneiras de se determinar as opções para CLO.

Metodologia para definição	Conjunto de opções	Erro máximo
Divisão uniforme do intervalo de CLO	0,3000; 0,3944; 0,4889; 0,5833; 0,6778; 0,7722; 0,8667; 0,9611; 1,0556; 1,1500	0,2201
Dez valores obtidos pelo algoritmo genético	0,3441; 0,4067; 0,4846; 0,5167; 0,5764; 0,6139; 0,7264; 0,8651; 1,0230; 1,0757	0,1602
Cada chave corresponde a uma peça de vestimenta (opção adotada)	Ver Tabela 7	<0,1602

4. CONCLUSÕES

Por meio da análise do modelo de Fanger e do uso de algoritmo genético para otimizações das opções dos parâmetros individuais, verifica-se que, para a elaboração de um sensor do índice PMV, a melhor forma para obtenção dos valores de MET e CLO são diferentes. Para MET, a melhor forma é que se tenha um conjunto discreto de opções que correspondam às atividades físicas que os indivíduos possam estar realizando. Neste caso, para a obtenção dos valores ótimos, escolhem-se cinco valores usuais e utiliza-se algoritmo genético para que este otimize as cinco demais opções. Para o parâmetro CLO, a melhor forma é fazendo com que cada uma das dez chaves seletoras corresponda a uma peça de vestimenta. Desta forma, a cada chave selecionada, o sistema adiciona o valor correspondente de CLO no valor de CLO usado para o indivíduo.

Após estas considerações e utilizando o método de otimização, conclui-se que um sensor de conforto térmico baseado no índice PMV, que faça uso das estratégias descritas para obtenção dos parâmetros MET e CLO, estará sujeito a erros máximos de 0,3623 e 0,1602, respectivamente. Portanto, este esforço visando a minimização dos erros destes dois parâmetros, sujeitos a grandes incertezas para sua obtenção, torna viável o uso de sensores de PMV em equipamentos climatizadores, pois estes são capazes de proporcionar conforto térmico para um valor de PMV igual a $0 \pm 0,5$ (ASHRAE, 1993).

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ASHRAE (1993) “Refrigerating and Air Conditioning Engineers”. American Society of Heating, Ventilating and Air-Conditioning Engineers. Atlanta. USA.
- FANGER, P.O. (1970) “Thermal Comfort – Analysis And Applications in Environmental Engineering”. McGraw-Hill Book Company. New York.
- FREIRE, R.Z. (2006). *Técnicas avançadas de controle aplicadas a sistemas de climatização visando conforto térmico*. Curitiba: Dissertação (Mestrado em Engenharia) - PPGEPS/CCET/PUCPR, Pontifícia Universidade Católica do Paraná.
- FREIRE, R.Z.; OLIVEIRA, G.H.C.; MENDES, N. (2005) “Thermal comfort based predictive controllers for building heating systems”. In: 16 IFAC World Congress. Prague, Czech Republic.
- GOUDA, M.M.; DANAHER, S.; UNDERWOOD, C.P. (2001) “Thermal comfort based fuzzy logic controller”. Building Services Engineering Research and Technology, v.22, n. 4, p. 237-254.
- HAMDI, M.; LACHIVER, G. (1999) “A fuzzy control system based on the human sensation of thermal comfort”. in: IEEE CONF. ON FUZZY SYSTEMS, USA.
- INNOVA (2005) “Thermal Comfort Theory”. Innova Air Tech Instruments A/S. Copenhagen.
- TREBIEN, R.; MENDES, N.; OLIVEIRA, G. H. C. (2006) “Análise do Modelo de Fanger (PMV) para desenvolvimento de sistemas de controle de climatizadores”. in: 11th Brazilian Congress of Thermal Engineering and Sciences, ENCIT-2006, Curitiba.
- TREBIEN, R.; MENDES, N.; OLIVEIRA, G. H. C. (2007), “Análise de Sensibilidade do Índice PMV e Regiões de Conforto Térmico Visando o Aperfeiçoamento de Controladores para Sistemas de Climatização”, Revista Ambiente Construído (aceito para publicação).