

COMPARAÇÃO ENTRE A UTILIZAÇÃO DE PLANEJAMENTO DE EXPERIMENTOS E REDES NEURAIS NA PREVISÃO DE PARÂMETROS DE QUALIDADE DE PEÇAS PLÁSTICAS INJETADAS

Maurício Bagueira de Vasconcellos Azeredo

Eng. de Processo e Ferramental – Laboratórios BBraun S.A.

Av. Eugênio Borges, 1092 – Arsenal – São Gonçalo – RJ – CEP 24210-130

mauricio.azeredo@bbraun.com

José Stockler Canabrava Filho

Depto de Engenharia Mecânica – POLI/UFRJ

Centro de Tecnologia Bloco G/Sala 204 – Cidade Universitária – RJ – CEP 21945-970

stockler@serv.com.ufrj.br

Resumo. Vários métodos têm sido desenvolvidos na tentativa de se prever parâmetros de qualidade de peças injetadas durante a sua moldagem. Esses métodos baseiam-se em modelos matemáticos capazes de estimar parâmetros como peso, dimensional e funcional, em função das variáveis do processo de injeção. Dentre esses métodos, destaca-se o Planejamento de Experimento (DOE) e as Redes Neurais Artificiais (ANN). Nesse trabalho, o uso do Planejamento de Experimentos e de Redes Neurais Artificiais foi comparado utilizando um caso prático. Os resultados mostraram que as variáveis de processo que afetam o resultado de um parâmetro de qualidade de peças injetadas podem ser de forma rápida e eficiente melhor identificadas e entendidas, utilizando os dois métodos estudados. Além disso, nenhum conflito foi detectado entre eles.

Palavras-chave: planejamento de experimentos, redes neurais artificiais, moldagem por injeção.

1. INTRODUÇÃO

O processo de injeção consiste, basicamente, em fundir o material plástico e força-lo a preencher a(s) cavidade(s) de um molde que dará a forma desejada a peça. Após o preenchimento total do molde, o material é mantido sob pressão durante um determinado tempo para compensar sua contração ao se resfriar. Essa etapa é chamada de recalque, ou compactação, e garante que todos os detalhes das partes moldantes do molde sejam preenchidos. Após o preenchimento completo, o molde se mantém fechado até que todo o material plástico no seu interior se solidifique, permitindo, então, a sua abertura e extração da peça pronta moldada.

As propriedades de peças moldadas por injeção são altamente dependentes das condições de processo utilizadas durante a sua moldagem. Peças idênticas e que são fabricadas com o mesmo material, mas sob diferentes condições de injeção, certamente, se apresentarão como peças acabadas com diferentes tensões internas e diferentes níveis de contração, ocasionando variações dimensionais e diferentes acabamentos superficiais. Isto significa que se comportarão de formas

distintas durante o uso ou durante os diversos processos de fabricação que se seguem após a moldagem.

Na tentativa de se prever parâmetros de qualidade de peças injetadas durante a sua moldagem, vários métodos têm sido desenvolvidos (Mok et al, 1999). Esses métodos baseiam-se em modelos matemáticos capazes de estimar parâmetros como peso, dimensional e aspecto visual, em função das variáveis do processo de injeção. Dentre esses métodos, destacam-se as o Planejamento de Experimentos (DOE), por sua praticidade e capacidade de identificar interações entre as variáveis, e as Redes Neurais Artificiais (ANN), pela possibilidade de geração de modelos não-lineares e por suas habilidades de autotreinamento.

As redes neurais artificiais são métodos computacionais de inteligência artificial inspiradas na estrutura do cérebro humano. Da mesma maneira que no cérebro, as redes neurais artificiais são organizadas na forma de um número de elementos individuais simples (os neurônios), que se interconectam uns aos outros, formando redes capazes de armazenar e transmitir informação provinda do exterior (Rumelhart e MacClelland, 1986).

O planejamento de experimentos consiste em uma série de testes nos quais, propositadamente, serão efetuadas mudanças nos dados de entrada de um processo (fatores), a fim de serem observadas as mudanças correspondentes nos dados de saída (resposta).

Muitos trabalhos experimentais foram feitos para investigar a influência dos parâmetros de processo nas propriedades das peças injetadas utilizando redes neurais artificiais (Kenig et al, 2002; Min e Shin, 2001; Lau et al, 2001 e Sadeghi, 2000) e planejamento de experimentos (Azeredo & Silva, 2003; Xuehong e Lau, 2001; Väätäinen et al, 1994 e Hawks et al, 1992).

Neste trabalho pretende-se realizar uma análise comparativa entre essas duas metodologias na previsão de um parâmetro de funcionalidade de uma peça plástica injetada.

2. PROCEDIMENTO EXPERIMENTAL

Como caso de estudo, a injeção de uma tampa plástica para utilização em frascos de soluções de infusão de um laboratório farmacêutico foi utilizada. A referida tampa é injetada em polietileno de alta densidade (HDPE) e tem grande complexidade de forma e estreitas faixas de tolerâncias de seus itens de especificação dimensionais e funcionais. Dentre os inúmeros itens que definem sua qualidade, a força de abertura de um lacre para adição de medicamentos foi escolhida pela grande relação entre os valores para sua ruptura e os parâmetros do processo de injeção (Azeredo et al, 2003). A Fig. (1) ilustra a funcionalidade da tampa.



Figura 1. Funcionalidade da tampa. Para abrir a porta de injeção, basta apertar e romper o lacre levantando-o. Após a abertura do lacre, pode-se, então, adicionar algum medicamento

Para estudar a influência dos parâmetros do processo de injeção na força de abertura do lacre, foram selecionados sete variáveis de injeção, conforme Tab. (1) a seguir. Os níveis estabelecidos para cada variável indicam os valores máximos e mínimos que cada uma pode ter sem comprometimento do processo.

Tabela 1. Conjunto das variáveis para análise da força de abertura do lacre e seus níveis de trabalho

Descrição das variáveis	Min	Max
A: Velocidade de injeção (valor %)	40	75
B: Temperatura do molde	25 $^{\circ}\text{C}$	45 $^{\circ}\text{C}$
C: Temperatura do material	205 $^{\circ}\text{C}$	235 $^{\circ}\text{C}$
D: Pressão de recalque	25 bar	45 bar
E: Tempo de recalque	2 s	3 s
F: Tempo de resfriamento	10 s	25 s
G: Velocidade de extração (valor%)	5	25

Após a seleção das variáveis de processo e seus níveis de trabalho, uma série de oito experimentos foi realizada, conforme um planejamento fatorial fracionado descrito na metodologia do planejamento de experimentos (Schmidt & Launsby, 1994). Esses dados foram utilizados para o treinamento de uma rede neural *multilayer feedforward* composta de três camadas, com 7 neurônios na camada de entrada, 3 neurônios na camada intermediária e 1 na camada de saída, cuja função de ativação utilizada nas camadas externas era linear e sigmoid na camada intermediaria (Masters, 1993). Para tal, o *software* Statistica Neural Networks foi utilizado. Uma representação esquemática da rede utilizada é mostrada na Fig. (2).

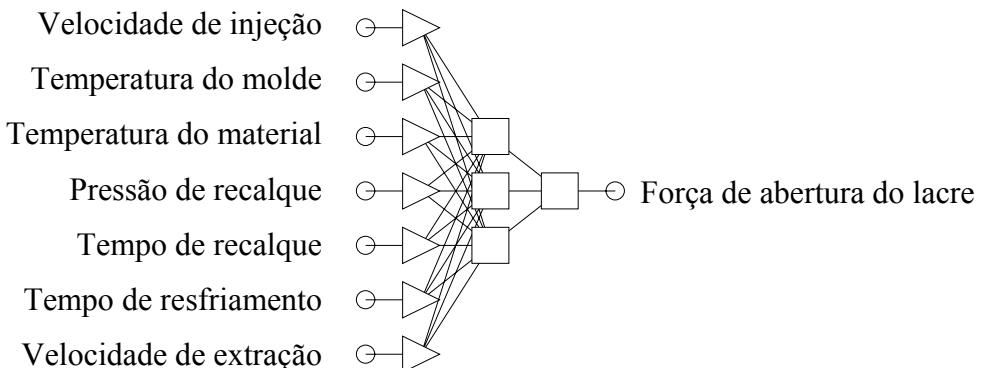


Figura 2. Representação esquemática da rede neural utilizada

Para posterior verificação do poder de previsão das metodologias em estudo, foram realizados mais oito experimentos, a partir do espelhamento da matriz de experimentos anterior. Essa técnica é denominada de *Foldover* e também é uma prática utilizada em planejamento de experimentos.

Em ambos os grupos de experimentos, três repetições foram realizadas para cada experimento. O resultado médio do valor da força de abertura do lacre, para cada experimento, é mostrado na Tab. (2) a seguir.

Tabela 2. Matriz de experimentos e resultados

Exp. Nr.	Variáveis							Força Média (N)	
	A	B	C	D	E	F	G		
TREINAMENTO	1	75	45	235	45	3	25	25	69,57
	2	40	45	235	25	2	25	5	41,14
	3	75	25	235	25	3	10	5	74,67
	4	40	25	235	45	2	10	25	62,35
	5	75	45	205	45	2	10	5	63,27
	6	40	45	205	25	3	10	25	40,97
	7	75	25	205	25	2	25	25	70,33
	8	40	25	205	45	3	25	5	42,32
VERIFICAÇÃO	9	40	25	205	25	2	10	5	42,99
	10	75	25	205	45	3	10	25	67,02
	11	40	45	205	45	2	25	25	32,89
	12	75	45	205	25	3	25	5	59,83
	13	40	25	235	25	3	25	25	50,15
	14	75	25	235	45	2	25	5	73,21
	15	40	45	235	45	3	10	5	32,50
	16	75	45	235	25	2	10	25	60,72

3. ANÁLISE E DISCUSSÃO DOS RESULTADOS

3.1. Análise de desempenho

Como parâmetro de comparação entre a metodologia do planejamento de experimentos e das redes neurais artificiais, adotou-se o coeficiente de correlação e a diferença (ou erro) entre os valores observados nos experimentos de verificação e os calculados em cada metodologia. Neste trabalho o erro será expresso pelo chamado “RMS error”, ou seja, pela raiz quadrada da média do quadrado das diferenças.

Para avaliar a desempenho da metodologia do planejamento de experimentos, foi criado um modelo quantitativo que relaciona a força de abertura do lacre com as variáveis estudadas. Esse modelo é descrito pela Eq. (1) e foi desenvolvido através de regressão linear múltipla (Draper & Smith, 1981), utilizando os dados de treinamento, sendo válido para a faixa operacional anteriormente definida na Tab. (1). A equação desse modelo é mostrada a seguir:

$$\hat{y} = 52,41 + 11,38 \left(\frac{A - 57,5}{17,5} \right) - 4,34 \left(\frac{B - 35}{10} \right) + 3,86 \left(\frac{C - 220}{15} \right) + 1,3 \left(\frac{D - 35}{10} \right) - 1,2 \left(\frac{E - 2,5}{0,5} \right) - 2,24 \left(\frac{F - 17,5}{7,5} \right) + 2,73 \left(\frac{G - 15}{10} \right) \quad (1)$$

Onde:

\hat{y} = Representa o valor estimado da força de abertura do lacre;

A = o valor da velocidade de injeção;

B = o valor da temperatura do molde;

C = o valor da temperatura do material;

D = o valor da pressão de recalque;

E = o valor do tempo de recalque;

F = o valor do tempo de resfriamento;

G = o valor da velocidade de extração.

No caso das redes neurais, os valores de desempenho foram obtidos diretamente do *software* Statistica Neural Networks.

Os resultados do coeficiente de correlação e do RMS *error* obtidos com ambas as metodologias são apresentados na Tab. (3).

Tabela 3. Cálculo do coeficiente de correlação e RMS *error*

Treinamento		Planejamento de Experimentos				Redes Neurais Artificiais			
Exp. Nr.	Força Observada	Força Estimada	Erro	Coef. de Correlação	RMS Error	Força Estimada	Erro	Coef. de Correlação	RMS Error
9	42,99	40,92	-2,07	0,907	6,037	51,61	8,62	0,949	6,245
10	67,02	69,36	2,34			71,77	4,75		
11	32,89	35,82	2,93			38,02	5,13		
12	59,83	48,14	-11,69			55,79	-4,04		
13	50,15	47,22	-2,93			53,64	3,49		
14	73,21	69,52	-3,69			70,58	-2,63		
15	32,5	40,16	7,66			41,17	8,67		
16	60,72	68,18	7,46			69,57	8,85		

Os resultados apresentados na Tab.(3) mostram que a diferença entre os valores de coeficiente de correlação e de RMS *erro* é muito pequena. Com isso, pode-se concluir que os desempenhos das metodologias estudadas na previsão da força de abertura do lacre são similares.

3.1. Resposta média

Com base nos resultados encontrados nos experimentos da Tab. (2), foi determinada, para cada variável, a resposta média nos níveis superior e inferior. Os resultados são mostrados na Tab.(4) a seguir.

O cálculo da resposta média é realizado, normalmente, quando se utiliza o planejamento de experimentos. Entretanto, no caso das redes neurais artificiais, essa análise só foi possível, pois nenhum comportamento não-linear foi detectado entre as variáveis.

Tabela 4. Resposta média nos níveis superior e inferior para cada variável

		A	B	C	D	E	F	G
Planejamento de Experimentos	Nível Sup.	69,46	53,74	61,93	59,38	56,88	55,84	60,81
	Nível Inf.	46,69	62,42	54,22	56,78	59,27	60,32	55,35
Redes Neurais Artificiais	Nível Sup.	69,47	55,86	62,99	61,84	60,13	57,01	65,10
	Nível Inf.	45,44	66,19	59,78	61,22	63,22	64,68	56,62

3.2. Efeito

O efeito de uma variável determina o impacto dessa variável no resultado final desejado. O efeito é calculado subtraindo a resposta média no nível superior da resposta média no nível inferior dessa variável. O efeito das variáveis em estudo é mostrado na Tab. (5) e representado graficamente na Fig. (3) a seguir.

Tabela 5. Efeito de cada variável na força de abertura do lacre

		A	B	C	D	E	F	G
Planejamento de Experimentos	Efeito	22,77	-8,68	7,71	2,6	-2,39	-4,48	5,46
Redes Neurais Artificiais	Efeito	24,02	-10,33	3,21	0,62	-3,09	-7,68	8,48

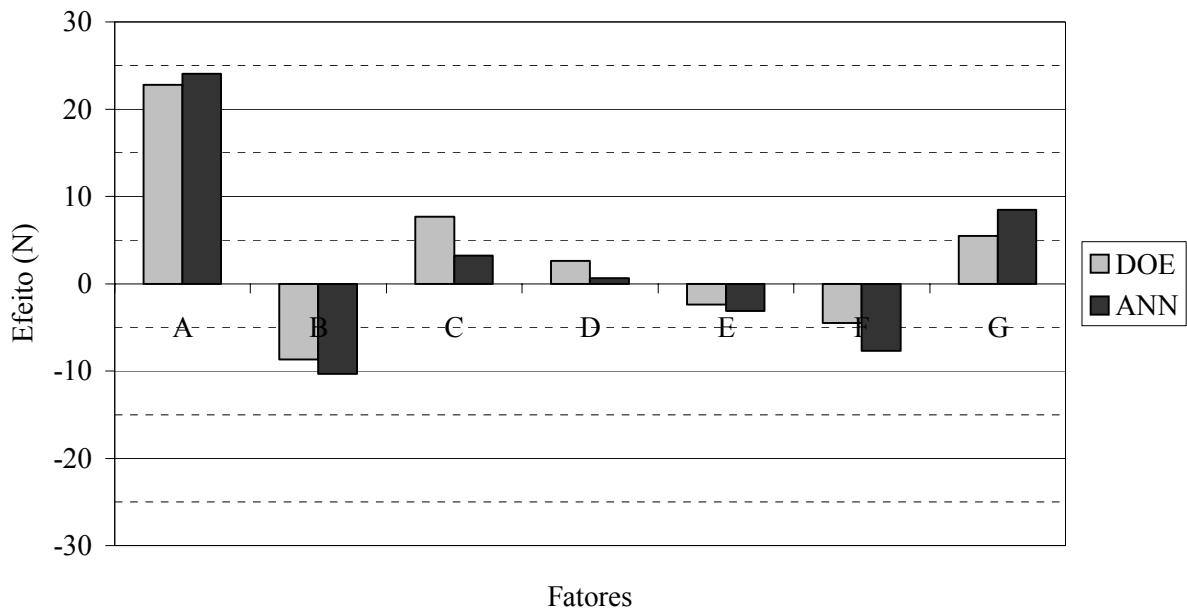


Figura 3. Representação gráfica efeito das variáveis de injeção na força de abertura do lacre

De acordo com os dados da Tab. (4) e (5), tanto para o planejamento de experimentos, como para a rede neural, as variáveis: velocidade de injeção (A), temperatura do material (C), pressão de recalque (D) e velocidade de extração (G) têm efeito positivo sobre a força de abertura do lacre. Ou seja, aumentando os seus valores, aumenta-se a força de abertura do lacre. Por outro lado, as variáveis: temperatura do molde (B), tempo de recalque (E) e tempo de resfriamento (F) têm efeito inverso.

A análise dos efeitos pode determinar, também, a importância de cada variável. Segundo o planejamento de experimentos, por exemplo, quando a velocidade de injeção (A) é elevada de 40% para 75%, a força de abertura do lacre passa de 46,69N para 69,46N em média. Um aumento, portanto, de 22,77N. Ou seja, houve um aumento médio de, aproximadamente, 50% na força.

Por outro lado, quando, por exemplo, a pressão de recalque (D) é elevada de 25bar para 45bar, a força de abertura do lacre passa de 56,78N para 59,78N. Um aumento, portanto, de 2,6N, o que é desprezível.

Dessa forma, podemos afirmar que o efeito da velocidade de injeção na força de abertura do lacre é muito mais significativo do que o efeito da pressão de recalque.

Contudo, nem sempre a análise dos efeitos é a melhor alternativa para a determinação das variáveis que mais influenciam a resposta desejada. Um enfoque alternativo para identificar a contribuição de cada variável é mostrado a seguir.

3.4. Contribuição

A contribuição de uma variável para a obtenção da resposta desejada pode ser definida por diversas técnicas descritas nas metodologias de planejamento e experimentos e redes neurais artificiais.

Neste trabalho, na analise do planejamento e experimentos, a contribuição de uma variável será calculada através de forma similar a Sanders et al (1992), utilizando a Eq. (2):

$$\text{Contribuição} = \frac{\Delta_i^2}{\sum_{i=1}^n \Delta_i^2} \times 100 \quad (2)$$

Onde:

Δ_i = Efeito de uma variável

n = Número de variáveis envolvidas

O resultado do cálculo da contribuição de cada variável conforme Eq. (2) é mostrado na Tab. (6).

Tabela 6. Contribuição de cada variável segundo o planejamento de experimentos

	A	B	C	D	E	F	G
Contribuição	72%	11%	8%	1%	1%	3%	4%

Nesse enfoque, são consideradas significativas apenas aquelas variáveis cuja contribuição é superior a 5%. Portanto, as variáveis que mais contribuem na obtenção da força de abertura do lacre são a velocidade de injeção (A), a temperatura do molde (B) e a temperatura do material (C).

No caso das redes neurais artificiais, a contribuição de uma variável será dada pela razão representada pela Eq. (3).

$$\text{Contribuição} = \frac{\text{RMS}_i}{\text{RMS}} \quad (3)$$

Onde:

RMS_i = Erro da rede eliminando a variável i

RMS = Erro da rede considerado todas as variáveis

Tabela 7. Contribuição de cada variável segundo o as redes neurais artificiais

	A	B	C	D	E	F	G
RMS_i	10,86	7,11	6,10	5,66	5,49	3,43	3,92
Contribuição	1,92	1,26	1,08	1,00	0,97	0,61	0,69

Nesse enfoque, são consideradas significativas apenas aquelas variáveis cuja contribuição é superior a 1. Portanto, as variáveis que mais contribuem na obtenção da força para abertura do lacre também são a velocidade de injeção (A), a temperatura do molde (B) e a temperatura do material (C).

Os cálculos das contribuições indicam que não existe divergência entre as duas metodologias estudadas.

4. CONCLUSÃO

Este trabalho se propôs a comparar a utilização da metodologia do planejamento de experimentos e das redes neurais artificiais na previsão de parâmetros de qualidade de peças plásticas injetadas. Para tal, utilizou-se como caso de estudo a injeção de uma tampa para frascos de uso médico-hospitalar. A influencia das variáveis do processo de injeção foram avaliadas na

determinação da força de abertura de um lacre presente na referida tampa. Os valores obtidos para o coeficiente de correlação e do RMS *error* suportam a conclusão as metodologias utilizadas têm um bom poder de previsão do parâmetro estudado e que, praticamente, não existe diferença de desempenho entre elas. Além disso, nenhuma diferença foi detectada na seleção das variáveis que têm maior contribuição na determinação da força estudada. Em ambos os casos as variáveis consideradas relevantes foram a velocidade de injeção, a temperatura do molde e a temperatura do material. Assim, concluiu-se que, tanto o planejamento de experimentos, como as redes neurais artificiais, pode ser utilizado no controle de parâmetros de funcionalidade de peças injetadas. Os resultados do trabalho estimulam a condução de estudos mais profundos, visando aperfeiçoar a aplicação conjunta dessas duas metodologias.

5. REFERÊNCIAS

- Azeredo, M.B.V.; Silva, S.S.; Rekab, K. "Improve molded part quality". *Quality Progress*. v. 36, n. 7, p. 72-76, 2003.
- Azeredo, M.B.V.; Silva, S.S. "Estudo identifica variáveis críticas que definem as dimensões de peças injetadas". *Plástico Industrial*. n. 62, p. 90-97, 2003.
- Draper, N.; Smith, H. *Applied Regression Analysis*, Wiley, 1981.
- Hawks, V.; Saunders, D.; Strong A.B. et al. "Determination of physical properties in injection molded composites using the design of experiments method". *Sampe Quarterly*. v. 23, n. 4, p. 46-52, 1992.
- Kenig, S.; Ben-David, A.; Sadeh, A. "Control of properties in injection molding by neural networks". *Engineering Applications of Artificial Intelligence*, 2002.
- Lau, H.C.W.; Ning A.; Chin K.S. "Neural network for dimensional control of molded parts based on reverse process model". *Journal of Materials Processing Technology*. n. 117, p. 89-96, 2001
- Masters T. *Practical Neural Network Recipes in C++*. Academic Press, 1993.
- Min, B.; Shin, B. "A Study on volumetric shrinkage of injection molded parts based on neural networks". *Journal of Injection Molding Technology*. v. 5, n. 4, p. 201-207, 2001.
- Mok, S.L; Kwong, C.K.; Lau, W.S. "Review of research in the determination of process parameters for plastic injection molding". *Advances in Polymer Technology*. v. 18, n. 3, p. 225-236, 1999.
- Rumelhart, D. E.; MacClelland, J. L.; and The PDP Research Group; *Parallel Distributed Processing*, Inst. for Cognitive Science - Univ. of California, The MIT Press, Vol.1, 1986.
- Sadeghi, B.H.M. "A BP-neural network predictor model for plastic injection molding process". *Journal of Materials Processing Technology*. n. 103, p. 411-416, 2000.
- Sanders, T.J.; Rekab, K.; Rotella, F.M. et al. *IEEE Trans. On Semiconductor Manufacturing*, v. 5, n. 4, p. 368-372, 1992.
- Schmidt, S.R.; Launsby, R.G. *Understanding Industrial Designed Experiments*, Air Academy Press, 1994.
- Väätäinen, O.; Järvelä, P.; Valta, K. Et Al. "The effect of processing parameters on the quality of injection molded parts by using the Taguchi parameter design method". *Plastics, Rubber and Composites Processing and Application*, v. 21, n.4, p. 211-217, 1994.

6. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.

COMPARING DESIGN OF EXPERIMENTS AND ARTIFICIAL NEURAL NETWORKS IN THE FORECAST OF QUALITY PARAMETERS OF INJECTION MOLDED PLASTIC PARTS

Maurício Bagueira de Vasconcellos Azeredo

Process Engineering – Laboratórios BBraun S.A.

Av. Eugênio Borges, 1092 – Arsenal – São Gonçalo – RJ – ZIP 24210-130

mauricio.azeredo@bbraun.com

José Stockler Canabrava Filho

Department of Mechanical Engineering – POLI/UFRJ

Centro de Tecnologia Bloco G/Sala 204 – Cidade Universitária – RJ – ZIP 21945-970

stockler@serv.com.ufrj.br

Abstract. Quite a few pieces of research have attempted at various approaches with the aim of predict the part quality online. They are based on mathematical models which describe the relationship between process parameters and product properties such as: part weight, dimensions and functionality. Experimental findings show that Design of Experiments (DOE) and Artificial Neural Network (ANN) have been used successfully used to make predictions. They could be conveniently adopted when there are experimental data available. This work presents a comparison between both methods by means of a case study. The results showed that the Design of Experiments and the Artificial Neural Network seemed quick, efficient and cost saving methods to investigate the effects of process parameters on injection molded parts. In addition, no conflict was detected among the results obtained by either methods.

Keywords: *design of experiments, artificial neural networks, injection molding.*