

Envío: 10-02-2012

Aceptación: 27-02-2012

Publicación: 02-05-2012

UTILIZACIÓN DE LA OPTIMIZACIÓN MULTICRITERIO Y REDES NEURONALES COMO MÉTODOS PARA LA MEJORA DE LA CALIDAD DE LAS PIEZAS OBTENIDAS POR MOLDEO POR INYECCIÓN DE TERMOPLÁSTICOS

USE OF MULTICRITERIA OPTIMIZATION AND NEURAL NETWORKS AS METHODS TO IMPROVE THE QUALITY ON PIECES OBTAINED BY THERMOPLASTIC INJECTION MOULDING

Miguel Ángel Sellés Cantó¹Elena Pérez Bernabeu²Samuel Sánchez Caballero³Miguel Ángel Peydró Rasero⁴

1. Ingeniero Técnico Industrial en Electrónica. Ingeniero de Organización Industrial. Doctor Ingeniero en Organización Industrial. Universidad Politécnica de Valencia. Instituto de Tecnología de Materiales.
2. Ingeniero de Organización Industrial. Doctor en Organización Industrial. Departamento de Estadística e investigación Operativa Aplicadas y Calidad. Universidad Politécnica de Valencia.
3. Ingeniero Técnico Industrial en Mecánica. Ingeniero de Organización Industrial. Doctor en Organización Industrial. Universidad Politécnica de Valencia. Instituto de Diseño y Fabricación Sector Automoción.
4. Ingeniero Técnico Industrial en Mecánica. Ingeniero de Organización Industrial. Universidad Politécnica de Valencia. Instituto de Tecnología de Materiales.

RESUMEN

El moldeo por inyección de termoplásticos es el proceso de fabricación de plásticos más utilizado en todo el mundo. Para poder fabricar piezas con la máxima calidad, se desarrolla una metodología que modeliza mediante una red neuronal dicho proceso. El error medio obtenido en la simplificación de dicho modelo es despreciable, siendo comprobado posteriormente mediante ensayos reales. Se determinan al mismo tiempo qué variables de entrada son las más influyentes en la calidad final de la pieza.

ABSTRACT

The thermoplastic injection molding manufacturing process is the most widely used plastic manufacturing process worldwide. In order to manufacture parts with the highest quality, a methodology that modelizes that process using a neural network has been developed. The average error obtained in the model simplification is negligible, then being tested by real tests. At the same time, the input variables that are most influential in the final quality of the piece are finally determined.

PALABRAS CLAVE

Red neuronal, optimización, inyección, plásticos, modelización.

KEY WORDS

Neural network, optimization, injection, plastics, modelization.

INTRODUCCIÓN

El estudio del proceso de moldeo por inyección de forma pormenorizada y extensa coincide con el aumento de la capacidad de producción de los equipos de inyección y del simultáneo incremento de la demanda de productos. Es de hecho el método de fabricación de plásticos más utilizado en todo el mundo. Por sus amplias posibilidades de generación de formas complejas y sus bajos costes, éste se convierte en un proceso de elevado volumen de producción y cuyos productos, que, sin embargo, presentan calidades finales fuertemente influenciadas por las condiciones de proceso. No obstante, la tendencia actual de mercado en la introducción de productos plásticos en sectores como automoción, electrónica o medicina, está exigiendo niveles de calidad muy elevados. De hecho, la calidad de las piezas obtenidas por este método de fabricación es el resultado de una combinación compleja entre el material, la pieza y el diseño del molde, y las condiciones de proceso, pudiendo ser cuantificada en función de su apariencia, dimensiones y características mecánicas ^[3]. Hasta hace poco tiempo, la calidad se controlaba en las empresas realizando ajustes en las máquinas de inyección mediante métodos de prueba-error durante la fase de puesta en marcha, en los que una serie de piezas se fabrican variando ligeramente los parámetros de proceso hasta que se alcanzan los requerimientos mínimos de calidad. Estos métodos, aparte de significar un esfuerzo adicional, incurren en un mayor gasto tanto de tiempo como de dinero ^[1].

Paralelamente, la introducción de la sensórica y de los microprocesadores en el control computerizado de las máquinas de inyección ha permitido abrir las posibilidades de optimización del proceso de inyección y, con ello, competir en niveles de calidad con los procesos de conformado de piezas metálicas. Estos aspectos han permitido que, en definitiva, el procesado por inyección de los materiales plásticos se transforme en un proceso susceptible de ser mejorado en cuanto a eficiencia y valor añadido.

Este interés se ha traducido, hasta la fecha, en el desarrollo de campos de investigación centrados en:

- Mejoras en la calidad de las piezas,
- Tecnología y desarrollo de materiales poliméricos,
- Tecnología y desarrollo de máquinas, equipos y sistemas de control,
- Tecnología del análisis estructural y diseño de moldes,
- Tecnología de procesado e influencia de los parámetros de proceso en la calidad de las piezas.

El control de la calidad es la meta y objetivo final de los controles sobre la máquina y el proceso. Para ello, se debe poder alcanzar la calidad deseada en la pieza ajuntando el mínimo número posible de parámetros ^[2].

La medición de la calidad en tiempo real es difícil de implementar con el moldeo por inyección, utilizando para ello sensores comerciales a un precio razonable. Considerándolo de forma estricta, es obvio que no existe un sistema de control por retroalimentación para el moldeo por inyección, y que todos los intentos por conseguir controlar dicha calidad terminan al final con un sistema de control basado en un observador.

Los modelos de calidad, que actúan como los observadores en el sistema de control, se implementan habitualmente utilizando métodos como las redes neuronales o los análisis de regresión. El hecho de que el sistema pueda regular y alcanzar el índice de calidad predefinido de forma correcta, depende en gran medida de la capacidad de adaptación a aquellas características que son variables con el tiempo.

Numerosos investigadores han visto distintos métodos posibles para conseguir un "observador" de la calidad para el proceso y el control de calidad que sea genérico, preciso y económico. Como índices de calidad, el peso de la pieza y las dimensiones de la misma, son las dos variables más utilizadas para representarla, porque se pueden medir cuantitativamente con muy alta precisión ^[5].

Woll y Cooper ^[6] han realizado una comparación entre diferentes modelos empíricos (modelo por regresión lineal, modelo estadístico y modelo de red neuronal) para predecir el peso y la longitud de una pieza. Concluyen en que el modelo ensayado de red neuronal proporciona la mejor predicción.

Rewal y Toncich ^[4] han utilizado también una red neuronal en su trabajo de investigación, para poder predecir el peso partiendo de la presión y temperatura en la boquilla. El peso de la pieza calculado se ajusta muy bien a los datos experimentales.

DISEÑO DE EXPERIMENTOS

La planificación experimental es un método utilizado para organizar los experimentos y encontrar, en un proceso, qué variables son significativas, cómo interactúan entre ellas, y cuál es la mejor condición que optimice el proceso.

Para ello se establece un diseño de experimentos (DOE) con el que se establezca la identificación de los factores (variables de proceso) que producen cambios en las variables respuesta (variables resultado de proceso).

Entre los distintos métodos que existen para desarrollar diseños de experimentos (diseños factoriales, diseños factoriales fraccionarios, análisis de regresión, superficie de respuesta, diseños por bloques,...), se adopta como técnica DOE la de diseño factorial fraccionado, utilizando para ello las matrices ortogonales propuestas por las técnicas Taguchi que permiten:

- Reducir a un valor mínimo el conjunto de simulaciones y ensayos a realizar para obtener resultados concluyentes sobre la interrelación entre las variables de proceso y los resultados del proceso considerados.

- Deducir la posible interrelación existente entre dos o más variables de proceso sobre un determinado resultado de proceso, de modo que no queden excluidas del análisis global.

Para la realización del diseño de experimentos, se han tomado en consideración las siguientes cinco variables de proceso (se han tenido en cuenta solamente estas cinco porque son controlables de forma directa por el operario ante la máquina de inyección de termoplásticos):

VARIABLE	ABREVIATURA	UNIDADES
Tiempo de inyección	TI	s
Temperatura de inyección	TP	°C
Temperatura del refrigerante	TM	°C
Nivel de presión de compactación	PC	%
Transición llenado-compactación (switch-over)	SW	%

Tabla 1: Las cinco variables de proceso del diseño de experimentos. Fuente: Elaboración propia.

Los modelos más usuales dentro del diseño mediante matrices ortogonales son los lineales, basados en dos niveles (2^{k-p}), y los de segundo orden, basados en 3 niveles (3^{k-p}). Será este último modelo el que se utilizará para el diseño de los experimentos, ya que se quiere obviar el inconveniente del empleo de expresiones lineales que impiden un ajuste muy preciso a la realidad de la modelización. Entonces, los tres niveles escogidos para las cinco variables de proceso anteriores serían:

VARIABLE DE PROCESO		NIVEL		
		-1	0	1
Tiempo de inyección	s	0,8	1,5	2,2
Temperatura de inyección	°C	220	240	260
Temperatura del refrigerante	°C	40	55	70
Nivel de presión de compactación	%	70	85	100
Transición llenado-compactación (switch-over)	%	94	96	98

Tabla 2: Niveles de las variables de proceso. Fuente: Elaboración propia.

Así pues, bajo la perspectiva de un diseño factorial, el número total de ensayos/simulaciones a realizar sería de $3^5 = 243$. Como puede apreciarse, es un número bastante elevado de ensayos, pero por suerte, existe el método Taguchi, que reduce de manera significativa la realización de todos los ensayos sin que ello afecte al resultado final.

Para la determinación, bajo estas condiciones, de la tabla de ensayos / simulaciones, se deben considerar las siguientes matrices ortogonales:

- L_{27} , correspondiente a 13 variables a 3 niveles (3^{13}). Esta matriz permite el estudio de las 5 variables anteriormente descritas, pero no se pueden tener en cuenta todas las interacciones entre ellas, por la limitación dada por esas 13 variables, ya que se necesitarían más.
- L_{81} , correspondiente a 40 variables a 3 niveles (3^{40}). En este caso ya se pueden evaluar las interacciones entre las 5 variables de proceso consideradas.

A priori, no se puede concluir que no existan interacciones entre las variables de proceso implicadas de cara a los posibles resultados de proceso, por lo que se descarta la tabla L_{27} para el presente estudio. Se adopta la tabla L_{81} , pues con ella se consigue considerar todas las interacciones de dos niveles entre los factores, y simultáneamente obtener una modelización polinómica de 2º orden para cada uno de los indicadores propuestos.

Después de aplicar el método de Taguchi y de utilizar sus gráficas lineales, se ha confeccionado un listado detallado de los experimentos a realizar, resultando un total de 81.

SIMULACIÓN DEL PROCESO

Para la obtención de los valores de las variables resultado de proceso para cada una de las simulaciones propuestas en las tablas D.O.E. se hace necesario el empleo de un software informático de simulación que permita la evaluación de dichos resultados a partir de las condiciones particulares propuestas en cada caso.

Son numerosos los paquetes informáticos disponibles en el mercado que permiten evaluar las condiciones de proceso dadas las premisas iniciales de cada simulación. En el presente trabajo se ha empleado el motor de cálculo del software de simulación *C-Mold*, que permite, mediante la especificación de los archivos de condiciones de proceso, de materiales, el mallado por elementos finitos de la geometría de la cavidad estudiada y los parámetros de cálculo, la obtención de los archivos con la información necesaria para evaluar las variables resultado de cada una de las simulaciones.

La definición de las condiciones de simulación debe estar definida en arreglo a las tablas de diseño de experimentos propuestas en la presente metodología.

El software *C-Mold* necesita para sus simulaciones de la siguiente información:

- Características del material. En nuestro caso, se ha utilizado ABS reciclado, procedente de viejas torres de ordenadores y carcasas de monitores. Los datos requeridos por el software se determinaron realizando mediciones reológicas sobre el material.
- Geometría del molde.
- Condiciones de proceso y características de la máquina. El equipo empleado para la experimentación es una inyectora Mateu & Solé, modelo Meteor 270/75 con las siguientes características principales:

- Diámetro del husillo (relación L/D): 35 mm (20,5)
- Presión máxima de inyección: 173,5 MPa.
- Volumen teórico de inyección: 155 cm³.
- Peso máximo de inyección (PS): 140 gr.
- Caudal máximo de inyección: 106 cm³/s.
- Fuerza de cierre: 750 kN.
- Zonas de calefacción: 4+1.

Una vez efectuados los análisis de cada una de las simulaciones, se generan un conjunto de archivos de resultados que incluyen de forma tabulada la información referente a los resultados de simulación.

Del conjunto de archivos de resultados que ofrece el software *C-Mold* tras el análisis, se extraen los distintos valores correspondientes a los resultados de proceso considerados para el estudio y para su procesamiento posterior. El listado de resultados de proceso considerados a nivel global del molde en la herramienta informática de extracción, y disponibles para su uso como indicadores de efecto es el mostrado en la Tabla 3.

VARIABLE	ABREVIATURA	UNIDADES
Presión máxima alcanzada	PRMM	MPa
Temperatura promedio ponderada máxima alcanzada	TPMM	°C
Tensión de cizalla en pared máxima alcanzada	TCMM	MPa
Velocidad de cizalla característica máx. alcanzada	VCMM	s ⁻¹
Fuerza de cierre máxima alcanzada	FCMM	Tm
Rango entre los valores de contracción máxima y de contracción mínima al final del proceso	RCOM	%
Pico máximo de la presión mínima alcanzada	PPMM	MPa
Contracción media al final del proceso	COPM	%

Tabla 3: Las ocho variables consideradas del resultado del proceso. Fuente: Elaboración propia.

OPTIMIZACIÓN MEDIANTE UNA RED NEURONAL

Las redes neuronales artificiales (ANN's, de sus siglas en inglés) intentan copiar en algunos de sus aspectos básicos a las funciones del cerebro. Se suelen utilizar en una amplia gama de tareas: desde simples cálculos hasta la ayuda a la toma de decisiones de alto nivel. Se han escogido las redes neuronales para el presente estudio por su buena adaptación en el ajuste de parámetros no lineales.

Las redes neuronales se componen de elementos de procesamiento o nodos. Estos se conectan entre ellos a través de una vía que permite un elevado grado de paralelismo entre sus funciones. Cada nodo solamente es capaz de realizar una operación muy simple. Para que la red pueda trabajar correctamente, es necesario que sufra antes un aprendizaje, que se consigue asignando unos pesos correctos a cada una de las conexiones entre los nodos, al ir cambiando estos pesos para minimizar el error relativo de las salidas. La red ya estará entrenada cuando los pesos hayan alcanzado un valor óptimo, al haber conseguido el mínimo error posible. Se puede ver un esquema de red neuronal en la Figura 1.




Figura 1: Elementos básicos que componen una red neuronal. Fuente: Elaboración propia.

En un principio, los modelos de redes neuronales eran bastante simples, y solamente eran capaces de realizar aproximaciones de funciones lineales. Fue en el año 1986 cuando Rumelhart y sus colaboradores desarrollaron un modelo de red neuronal, denominado *Back Propagation (BP)*, el cual era capaz de realizar ajustes con funciones no lineales, realizando un aprendizaje de la red por corrección del error, cambiando los pesos de las conexiones para progresivamente ir reduciendo el error en la salida.




Figura 2: Entradas y salidas en una neurona. Fuente: Elaboración propia.

Como se puede apreciar en la Figura 2, la salida de una neurona o elemento de procesamiento es una función no lineal de sus entradas. Una vez ya esté entrenada la red, se introducen nuevas entradas, y se predicen automáticamente los valores para las respectivas salidas.

Para conseguir el objetivo propuesto, se ha construido una red neuronal con la ayuda de un software específico. El entrenamiento se ha realizado mediante la utilización del algoritmo Back Propagation (BP), partiendo del establecimiento aleatorio de los pesos iniciales entre las conexiones de las neuronas.

El diseño óptimo de la red neuronal para la modelización buscada se ha conseguido después de 17363 ciclos de entrenamiento, y consta de una capa de entrada con las cinco variables de proceso (Tabla 1), de una capa oculta con 33 neuronas, y por último, de una capa de salida con las ocho variables consideradas (Tabla 2). En total existen 429 conexiones (Figura 3). El error medio alcanzado es de $5 \cdot 10^{-5}$.




Figura 3: Estructura de la red neuronal. Fuente: Elaboración propia.

Como se puede apreciar, la precisión del modelo de red neuronal es asombroso, y perfectamente válido, pero difícilmente se pueden obtener conclusiones concretas de las variabilidades de las salidas, si no se estudian por separado.

Para ello se han construido un total de 8 redes, todas con una única salida, para conocer de manera individual y pormenorizada los efectos de las entradas sobre cada una de estas 8 variables consideradas resultado de proceso. En todas estas redes, el error medio alcanzado ha sido de $5 \cdot 10^{-5}$. Para todas ellas, el software utilizado ha proporcionado un análisis de sensibilidad, que muestra cómo cambia una salida cuando se producen variaciones en las entradas. Todas las entradas se ajustan a valores medios y se van incrementando desde el valor más bajo hasta el más elevado. En la Tabla 4 se muestran los resultados obtenidos.

SIMPLIFICACIÓN DE LOS MODELOS INDIVIDUALES PARA CADA UNA DE LAS VARIABLES DE SALIDA.

Si se establece como criterio que aquellas entradas cuyo efecto en la sensibilidad de la salida sea inferior a 0'10, afectan poco al resultado final, entonces la Tabla 4 se puede simplificar eliminando las entradas que se encuentren por debajo de este valor, quedando como se muestra en la Tabla 5.

De la Tabla 5 se puede comprobar que existen tres entradas (Tiempo de inyección, Temperatura de inyección y Nivel de presión de compactación) que son las que más influyen en el comportamiento de cada una de las salidas (en concreto, en cinco variables); mientras que las otras 2 entradas (Temperatura del refrigerante y Transición llenado-compactación) tan solo se tendrían en cuenta en 2 salidas.

VARIABLE	Ciclos de aprendizaje	Nodos en capa oculta	Error máximo	Error medio	SENSIBILIDAD				
					Tiempo de inyección	Temp. De inyección	Temp. Del refrigerante	Nivel de presión de compactac.	Transición llenado-compactac.
PRMM	10162	33	7,49E-4	5E-5	0,1989	0,6015			
TCMM	13862	32	1,34E-3	5E-5		0,3611		0,3868	
VCMM	81	32	1,82E-4	5E-5	0,9824				
FCMM	8368	32	1,40E-3	5E-5				0,6000	0,1863
TPMM	2409	32	2,96E-4	5E-5		0,9695			
RCOM	10341	32	8,21E-4	5E-5	0,2319	0,1064	0,3841	0,1126	
PPMM	14874	32	1,91E-3	5E-5	0,2612	0,1996		0,4831	0,1439
COPM	7621	34	1,08E-3	5E-5	0,2613		0,1750	0,4559	

Tabla 4: Análisis de sensibilidad para cada una de las redes generadas. Fuente: Elaboración propia.

A este resultado se podía llegar también analizando la red neuronal general mostrada en la Figura 3, de la que se obtienen los datos de importancia de la Tabla 6, proporcionados por el software utilizado. Como se puede apreciar, las tres entradas con un mayor peso de importancia coinciden con las mencionadas en el anterior párrafo.

VARIABLE	Ciclos de aprendizaje	Nodos en capa oculta	Error máximo	Error medio	SENSIBILIDAD				
					Tiempo de inyección	Temp. De inyección	Temp. Del refrigerante	Nivel de presión de compactac.	Transición llenado-compactac.
PRMM	10162	33	7,49E-4	5E-5	0,1989	0,6015			
TCMM	13862	32	1,34E-3	5E-5		0,3611		0,3868	
VCMM	81	32	1,82E-4	5E-5	0,9824				
FCMM	8368	32	1,40E-3	5E-5				0,6000	0,1863
TPMM	2409	32	2,96E-4	5E-5		0,9695			
RCOM	10341	32	8,21E-4	5E-5	0,2319	0,1064	0,3841	0,1126	
PPMM	14874	32	1,91E-3	5E-5	0,2612	0,1996		0,4831	0,1439
COPM	7621	34	1,08E-3	5E-5	0,2613		0,1750	0,4559	

Tabla 5: Eliminación de aquellas entradas que producen poca variación en la sensibilidad.

Fuente: Elaboración propia.

VARIABLE DE ENTRADA	IMPORTANCIA RELATIVA
Tiempo de inyección	78,48
Temperatura de inyección	75,90
Nivel de presión de compactación	61,54
Transición llenado-compactación	39,51
Temperatura del refrigerante	36,60

Tabla 6: Importancia relativa de cada una de las entradas en la red neuronal general.

Fuente: Elaboración propia.

Llegados a este punto, es importante demostrar que esta simplificación del modelo general (con todas las variables de salida consideradas y solamente las tres entradas más importantes) y de los modelos particulares (con cada variable de salida estudiada por separado) no afecta de manera significativa a la precisión obtenida en las anteriores redes. De hecho, se puede apreciar en la Tabla 7 que el error medio cometido en seis modelos simplificados es exactamente el mismo que los correspondientes completos, y por tanto, no se comete error adicional al eliminar determinadas variables en los modelos completos. El mayor de los otros errores restantes es de $1,3 \cdot 10^{-3}$, siendo también un error despreciable. Por tanto, y en vista de los anteriores resultados, se puede afirmar que la simplificación es totalmente válida, no viéndose afectadas las variables de salida por la eliminación de las correspondientes entradas.

MODELO SIMPLIFICADO					
VARIABLE	ESTRUCTURA RED	NODOS OCULTOS	CONEXIONES	CICLOS	ERROR MEDIO
TODAS	3x22x8	22	242	10100	4,9E-3
PRMM	2x5x1	5	15	13161	5E-5
TCMM	2x4x1	4	12	13587	5E-5
VCMM	1x3x1	3	6	735	5E-5
FCMM	2x5x1	5	15	11657	5E-5
TPMM	1x3x1	3	6	794	5E-5
RCOM	4x7x1	7	35	98000	7,7E-4
PPMM	4x5x1	5	25	124000	1,3E-3
COPM	3x7x1	7	28	15267	5E-5
MODELO COMPLETO					
VARIABLE	ESTRUCTURA RED	NODOS OCULTOS	CONEXIONES	CICLOS	ERROR MEDIO
TODAS	5x33x8	33	429	17363	5E-5
PRMM	5x32x1	32	192	10164	5E-5
TCMM	5x32x1	32	192	13862	5E-5
VCMM	5x32x1	32	192	81	5E-5
FCMM	5x32x1	32	192	8368	5E-5
TPMM	5x32x1	32	192	2409	5E-5
RCOM	5x32x1	32	192	10341	5E-5
PPMM	5x32x1	32	192	14874	5E-5
COPM	5x32x1	32	192	7621	5E-5

Tabla 7: Comparación de errores entre los modelos simplificados y los completos. Fuente: Elaboración propia.

CONCLUSIONES

Se ha demostrado experimentalmente la validez de los modelos simplificados presentados en este trabajo, coincidiendo las dos en los resultados obtenidos, por lo que quedarían probadas las argumentaciones presentadas en el presente estudio.

Aunque el modelo descrito ha sido desarrollado con el uso de 5 variables de proceso, se puede extender al conjunto de variables de proceso que el centro decisor desee considerar, aunque debe tenerse en consideración que, a efectos de simulación de proceso, las variables seleccionadas deben estar contempladas. Con esta alternativa se puede ampliar la definición de los indicadores propuestos o introducir nuevos indicadores que se adapten mejor a los efectos que están valorando.

Asimismo, la posibilidad de estudio que esta metodología de optimización ofrece para cualquier geometría, garantiza que su campo de aplicación se pueda extender a un sinfín de geometrías complejas y casos particulares.

Los resultados experimentales obtenidos ponen de manifiesto como los efectos evaluados sobre las piezas inyectadas siguen el patrón de tendencias que los indicadores señalan, al tiempo que validan los criterios de optimización considerados al mantener los valores más idóneos de los parámetros medidos.

REFERENCIAS

- [1] **Zhongbao CHEN, Lih-Sheng TURNG.** Advances in injection molding process/quality control. *ANTEC*, págs. 697-701, 2004.
- [2] **Zhongbao CHEN, Lih-Sheng TURNG.** A review of current developments in process and quality control for injection molding. *Advances in Polymer Technology*, 24(3):165-182, 2005.
- [3] **Cybele LOTTI, Rosario E.S. BRETAS.** Using neural networks to predict injection molded ipp shrinkage.
- [4] **Navneet REWAL, Dario TONCICH.** Predicting part quality in injection molding using artificial neural networks. *Journal of injection molding technology*, 2(3):109-119, Septiembre 1998.
- [5] **James J. WENSKUS.** Part weight as a control metric for injection molding. *Journal of Injection Molding Technology*, 1(3):151—157, 1997.
- [6] **Suzanne L.B. WOLL, Douglas J. COOPER, Blair V. SOUDER.** Online pattern-based part quality monitoring of the injection molding process. *Polymer engineering and science*, 36(11):1477—1488, 1996.