

COMBINACION DE LOS ELEMENTOS FINITOS Y LA INTELIGENCIA ARTIFICIAL PARA LA OPTIMIZACION DE MODELOS DE MAQUINADO.

**Dr. C. Ramón Quiza Sardiñas¹, Msc. Omar López Armas², Dr. C. Marcelino Rivas
Santana³**

*1. Universidad de Matanzas “Camilo Cienfuegos”, Vía Blanca
Km.3, Matanzas, Cuba.*

Resumen.

En esta monografía se presenta, las combinaciones de técnicas del método de elemento finito y de la inteligencia artificial para modelar y optimizar operaciones de fabricación se resumen. Puesto que esto es relativamente un nuevo tema, no sólo se revisan y se destacan los informes de la literatura, pero también se presentan algunos conceptos e ideas básicas, y se exponen las tendencias futuras renunciadas. Un estudio de caso se desarrolla en el extremo del material, para ilustrar el uso de este acercamiento.

Palabras claves: Elementos Finitos, Inteligencia Artificial, Optimización.

Cuerpo de la monografía.

Se ha probado el método de elemento (FEM) finito siendo una herramienta versátil y potente para solucionar problema complejo en campos muy diversos de la ingeniería, de la dinámica de fluidos y del traspaso térmico a la deformación plástica de sólidos. Su capacidad para aproximar las soluciones de las ecuaciones diferenciales parciales definidas sobre los ámbitos complejos del espacio y de tiempo, substituyéndolos por los sistemas de ecuaciones algebraicas lineares, es la fundación del poder real del mercado de cambios. Puede ser utilizada con éxito para obtener soluciones numéricas de modelos fenomenológicos complejos

Sin embargo, el mercado de cambios tiene una desventaja principal: es muy costoso desde el punto de vista de cómputo. lo modelos Mercado de cambios-basados requieren generalmente los ordenadores potentes (o, incluso, racimos del ordenador) para satisfacer sus necesidades del cómputo. También, llevan la considerable cantidad de tiempo para ser solucionado. Por lo tanto, el uso de estos modelos para optimizar proceso de fabricación (no sólo mientras que la blanco funciona pero también como apremios) es limitado, porque prácticamente todas las técnicas de optimización exigen evaluaciones múltiples de los modelos implicados.

Por otra parte, las técnicas de la inteligencia artificial (especialmente, los que se clasifican como suaves computando, por ejemplo redes neuronales, lógica confusa, algoritmos evolutivos, el etc.), han probado ser eficaces para modelar y optimizar los problemas complejos [DIX08]. Estas técnicas requieren comúnmente mucho tiempo y esfuerzo de cómputo para ser adaptado encima de (o para ser entrenado), pero los modelos obtenidos pueden estar fácilmente y rápidamente evaluaron.

Debe ser evidente que combinar estas dos herramientas potentes sería resultado en un acercamiento híbrido más robusto y más eficaz para establecer modelos proféticos en el corte. Sin embargo, al mejor de nuestro conocimiento, no hay un número grande de trabajos publicados sobre esta línea. Podría ser causada por la alta complejidad de ambas técnicas, que anima el uso del software específico (por ejemplo, DEFORMEN y mercado de cambios de ADVANTEDGE, porque modelado basado elemento finito de trabajar a máquina, y

MATLAB y WEKA, para las técnicas de la inteligencia artificial). Estos programas son generalmente incompatibles o, en menos, muy difíciles ser combinado.

Sin embargo, el aumento continuo en el poder de computación en máquinas del ordenador, así como el desarrollo de un software más potente y más flexible, está abriendo actualmente la puerta en este nuevo acercamiento híbrido.

Una breve descripción en técnicas de la inteligencia artificial (AI).

En esta sección, las técnicas de AI más usadas, que se combinan con el elemento finito para los procesos de fabricación de modelado y óptimos, se describen brevemente. Debe ser señalado que la blanco principal de esto secciona no está dando un fondo teórico en estas técnicas (que esté fuera de los límites de este capítulo) pero ofreciendo el conocimiento imprescindible para entender los usos revisados en la sección siguiente.

Técnicas de AI para modelar.

Base de las técnicas de AI para modelar.

Las técnicas artificiales para modelar apuntan establecer una relación matemática entre algún dependiente, x , y variables independientes, y :

$$y = f(x) . \quad (E.1)$$

Sin embargo, la antes de que la relación mencionada no sea una expresión matemática simple, solamente asociación compleja, que es obtenida usando los paradigmas que imitan el razonamiento humano. Por ejemplo, las redes neuronales imitan la estructura interconectada simple de los nodos del cerebro, mientras que la lógica confusa trata de extrapolar como lo hacen los pensamientos humanos generalmente.

Debe ser acentuado que los modelos basados de la inteligencia artificial son modelos empíricos, porque utilizan datos experimentales para extraer la información de ellos. Esto es un punto clave, porque uno no puede contar con un modelo inteligente que es más exacto que son sus datos experimentales.

Además, como otros modelos empíricos, AI-basados no pueden tener parámetros más libres que se determinarán que el número de pares de los datos disponibles para entrenar. En este caso, el proceso del entrenamiento llega a ser matemáticamente indeterminado [SHA07].

Redes neuronales artificiales (ANN).

Las redes neuronales artificiales (ANN) son las estructuras conexionistas que modelan las operaciones de los sistemas de los nervios biológicos [HU02]. Sin embargo, pueden ser consideradas, más allá de cualquier interpretación biológica, como clase de general, de modelos de regresión no lineales flexibles, para encontrar la relación entre las variables de entrada y las variables de salida [DOD04].

Cualquier red neuronal artificial es compuesta por un número de unidades de cómputo simples, “neuronas supuestas” (inspiradas por las neuronas biológicas). Se interconectan estas neuronas (o los nodos), así que la salida de una (o algo) de ellas son la entrada del otro uno.

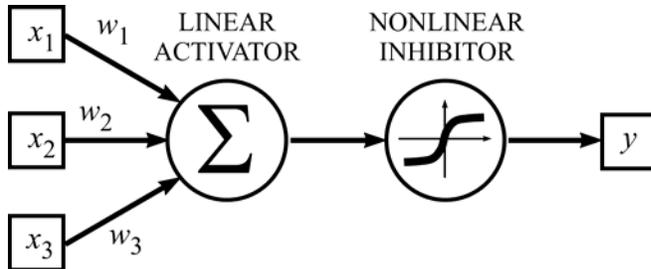


Fig. 1. Modelo de Neurona Artificial.

Una neurona artificial (véase a Fig. 1) es compuesta por una o más sinapsis, llevando las entradas en la neurona, y salida, y una función de transferencia, con relaciona entradas y salida. Las sinapsis cargan la entrada para reflejar la fuerza relativa de la conexión. La función de transferencia es compuesta generalmente por un activador lineal y un inhibidor no lineal. Por lo tanto, el funcionamiento de una neurona artificial se puede modelar matemáticamente como:

$$y = f(b + \sum_i w_i x_i), \quad (E.2)$$

donde está un prejuicio b supuesto del término independiente, que expresan la tendencia de la neurona a ser activado.

Una red neuronal se puede representar como gráfico directo, era neuronas se arregla en capas. Dependiendo de cómo se interconecta la capa, las redes neuronales se clasifican como alimentación-delanteras o periódicas.

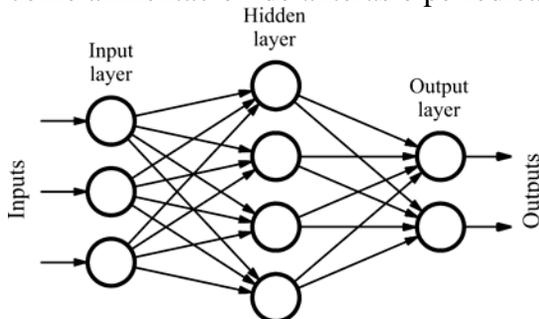


Fig.,2 Red Alimentación Delantera.

Las redes Alimentación-delanteras se componen para varias capas cuyas salidas estén conectadas solamente con las neuronas en las capas posteriores (véase a Fig. X.2), es decir, sólo existen las conexiones delanteras. Las muestras bien conocidas de estas redes neuronales son el perceptrón de múltiples capas (MLP), las redes radiales de la función de base (RBF) y los mapas de auto-organización (SOM).

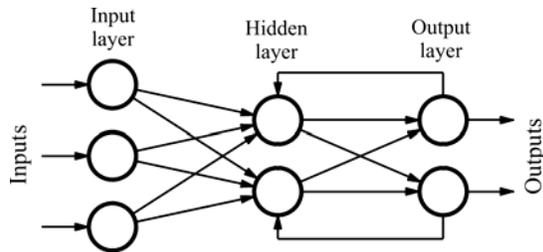


Figura X.3. Red periódica.

Independientemente de su topología y más allá de cualquier interpretación biológica, una red neuronal se puede ver una clase general de funciones, en la forma:

$$y = f(\mathbf{x}, \boldsymbol{\mu}), \quad (\text{X.3})$$

donde está el de $\mathbf{x} \{x_1, x_2, \dots, x_n\}$ T es el vector de las≡valor y previsto, el m ,} T es el vector μ_1, \dots, μ_l , el $\mu = \{\mu_l$ variables de entrada y el de los parámetros de red.

El proceso de encontrar los valores más convenientes de estos parámetros, para minimizar el error entre los valores deseados (blanco) y previstos de la variable dependiente, y , se llama entrenamiento de la red o aprendizaje, y el sistema usado a este propósito, entrenando al sistema. Este proceso del entrenamiento se puede clasificar como el aprendizaje supervisada, no supervisada o del refuerzo.

En el aprendizaje supervisado, el sistema del entrenamiento es compuesto por los ejemplos que son, realmente, pares que consisten en una entrada y una salida deseada. El algoritmo analiza los datos del entrenamiento para extraer la información útil y realizar tarea de la clasificación o de la regresión (dependiendo de cuando la salida es discreta o continua). Es importante la capacidad de la generalización, es decir, la capacidad para los valores de la salida que predicen para los datos no contenidos en el sistema del entrenamiento. Este tipo del entrenamiento se utiliza en los perceptrones multijugadores (MLP), las redes radiales de la función de base (RBF), redes neuronales periódicas (RNN) y redes neuronales de retraso de tiempo (TDNN), entre otros.

Al aprender contrario, no supervisado se ocupa de datos no-etiquetados, es decir, con los datos compuestos solamente por los valores de la entrada. El propósito principal de esta clase de aprendizaje es determinar cómo se organizan los datos. Algunos paradigmas bien

conocidos de la red neuronal que utilizan el aprendizaje no supervisado son la teoría adaptante de la resonancia (ART) y los mapas de auto-organización (SOM).

Finalmente, el aprendizaje del refuerzo es inspirado por vieja psicología del conductista. Trata a cómo un agente debe tomar medidas en un ambiente para maximizar una cierta noción de la recompensa acumulativa. El aprendizaje del refuerzo diferencia del aprendizaje supervisado estándar en que los pares correctos de la entrada-salida nunca están presentados, ni de acciones subóptimas corregidas explícitamente. Algunos de estos algoritmos son la programación neuro-dinámica

El algoritmo de aprendizaje estudiado más de uso general y mejor es la retropropagación (una abreviatura para "al revés la propagación de errores "), que es una aplicación de la regla del delta (una generalización del menos algoritmo de las medias cuadradas, usada originalmente para los perceptrones lineares). Es un algoritmo de aprendizaje supervisado creado para los perceptrones de múltiples capas.

La retropropagación implica dos etapas. Primer es el cómputo de las salidas de cada capa (usando las entradas, en la primera capa, y las salidas de las capas precedentes, en las siguientes), en el paso de propagación delantero supuesto. En las segundas etapas, el error de la capa de la salida se computa, como la diferencia entre los valores deseados y computados, y entonces, en el paso hacia atrás, estos errores se propagan en las capas anteriores, para poner al día los pesos y los prejuicios.

A pesar de varios defectos bien conocidos (lentitud, convergencia no garantizada, tendencia a los mínimos locales, etc.), la retropropagación ha alcanzado muchos usos acertados en diversos campos y sigue siendo que era el algoritmo de aprendizaje más usado.

Lógica confusa.

La lógica convencional o booleana se ocupa de los predicados cuyo grado de verdad es verdad o falso. Inversamente, la lógica confusa se ocupa de los predicados que pueden tomar valores de la verdad entre cero (representando totalmente falso) y uno (totalmente verdad). Esto resulta más apropiado no sólo para tratar conocimiento lexicográfico pero también para manejar diversa clase de incertidumbres en sistemas físicos.

Aunque la lógica confusa y la lógica de probabilidad ambas tengan valores de verdad el extenderse a partir de la cero a uno, la interpretación de esto valora es conceptual diferente. Mientras que en lógica de probabilidad, los valores de verdad representan probabilidad, en lógica confusa que corresponden a los grados de verdad. La lógica confusa utiliza grados de la verdad como modelo matemático de la imprecisión mientras que la probabilidad es un modelo matemático de la ignorancia.

En el mismo alcohol, una variable borrosa se define como miembro de un sistema borroso. La función supuesta de la calidad de miembro define el grado de calidad de miembro a este sistema de un elemento. Por ejemplo, la "velocidad variable borrosa" (velocidad del corte del significado en un proceso de torneado), puede ser miembro de los sistemas "bajos", del "medio" o de "alto". Las funciones respectivas de la calidad de miembro se dan en Fig. X.4. En esta muestra, un valor de la velocidad de 450 m/min, tiene un grado de calidad de

miembro igual a cero, al sistema “bajo”, así que significa que esta certeza del valor no es un miembro de este sistema. En el contrario, tiene un grado de calidad de miembro de 0,3 al sistema “medio” y de 0,5 al sistema “alto”.

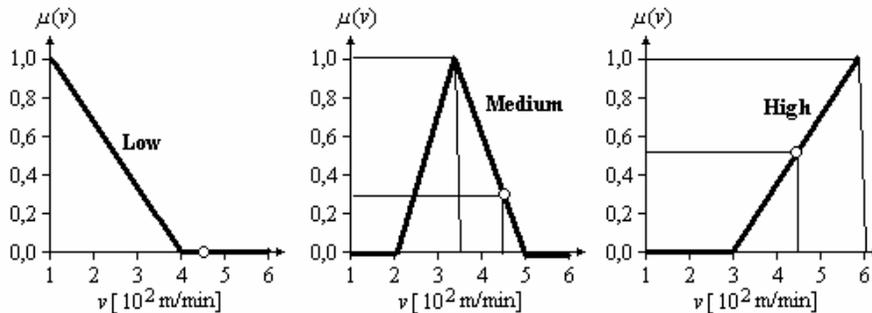


Figura X.4. Ejemplos de las funciones de la calidad de miembro.

Acercamientos para combinar el mercado de cambios y el AI en la investigación que trabaja a máquina.

Acercamientos para combinar el mercado de cambios y el AI en el modelado que trabaja a máquina.

Acercamiento de FEM/AI.

Las técnicas del método de elemento finito y de la inteligencia artificial se pueden combinar de varias maneras para realizar el modelado de los procesos de fabricación. El más natural, y divulgado más en la literatura [SHA09a, SHA09b, ZHA08, CHA08, GUD08, UMB08, UMB07, MAN06, LIN05, BOI04, RAY04, KIM00] de éstos unos, se representa en Fig. X.1.

En este acercamiento, un método de elemento finito se establece y se adapta para arriba, basado en suposiciones teóricas (tales como relaciones constitutivas entre las variables implicadas), y datos experimentales (que contienen los valores reales para los parámetros implicados, medidos experimental). Los resultados de este modelo basado del elemento finito se utilizan para entrenar a un aproximador inteligente de la función, cuyos resultados son los reales previstos valoran para el modelo entero.

Pues los aproximadores de la función son generalmente las redes neuronales artificiales usadas [SHA09b, CHA08, GUD08, UMB08, MOH07, UMB07, KIM00] pero se pueden seleccionar otras técnicas inteligentes, tales como reglas borrosas [MAN06], sistemas de inferencia neuro-borrosos [SHA09, BOI04] o redes abductive [LIN05, LIN04].

Los usos de esto acercamiento a diversos procesos de fabricación se han divulgado. Incluyen (pero no se limitan) los procesos que trabajan a máquina [UMB08, UMB07], el metal que forma [CHA08, KIM00], la protuberancia fría y de laminado en caliente [SHA09b, GUD08], caliente [SHA09], la hidroreformación [MOH07, MAN06, LIN04], el pulido mecánico químico [LIN05] y el proceso seleccionado de la sinterización del laser del polvo titanium [BOI04].

La ventaja principal de este acercamiento, en comparar con un modelo de elemento finito simple, es la velocidad de computación. Sin embargo, esto no es un punto trivial, considerando ese, como fue observado previamente, optimización de procesos que trabajan a máquina, especialmente al usar técnicas matemática heurística, requiere muchas evaluaciones de las funciones implicadas.

Acercamiento de AI/FEM.

Otro acercamiento para combinar las herramientas del método de elemento finito y de la inteligencia artificial se representa en Fig. X.2. En este acercamiento, una técnica inteligencia-basada artificial se utiliza para emparejar las relaciones entre algunos parámetros importantes (tales como tensión de producción o coeficiente de la fricción) y sus variables independientes respectivas (temperatura, tarifa de tensión, etc.).

La salida de la técnica inteligente, es decir el modelo empírico, se utiliza como entrada para el modelo elemento-basado finito, en conjunto con el conocimiento teórico. Finalmente, los valores previstos del modelo entero son los resultados del modelo elemento-basado finito.

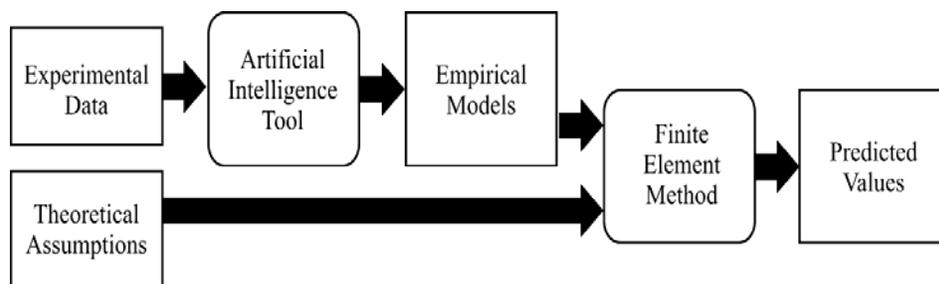


Figura X.2. Acercamiento de AI/FEM para el modelado que se trabaja a máquina.

Javadi y los compañeros de trabajo [JAV03] han propuesto un acercamiento finito “inteligente” del elemento donde una red neuronal se incorpora en el código del mercado de cambios para modelar la relación constitutiva del material. Demandan que las ventajas principales de usar un acercamiento de la red neuronal son que todos los aspectos del comportamiento material se pueden ejecutar dentro de un ambiente unificado de una red neuronal; no hay necesidad de relaciones matemáticas complicadas; no hay parámetros materiales que se identificarán y la red se entrena directamente de datos experimentales. La red neuronal es capaz de capturar las características principales del comportamiento material mientras que es entrenada por los datos experimentales.

Otro modelo red-basado de los nervios se ha desarrollado por Sun y otros [SUN10] para predecir la tensión del flujo para una aleación titanio, en función de la temperatura, de la tensión y de la tarifa de tensión. En el papel no se señala la posibilidad de usar este modelo en el mercado de cambios, pero esto está implícito. Además, varios problemas importantes sobre la puesta en práctica numérica de este acercamiento se han señalado [HAS04], para garantizar la convergencia del método.

Este acercamiento ha sido aplicado directamente a un proceso del balanceo [DAS07], usando un sistema neuro-borroso para predecir las propiedades materiales que son

utilizadas por un elemento finito de los autómatas celulares (CAFE), ejecutados en ÁBACO.

En un acercamiento interesante, Fu y los co-autores [FU10] utilizaron un tipo de múltiples capas red neuronal del perceptrón para modelar el radio óptimo del sacador, en un aire-doblez de la chapa. Entonces, con el radio previsto del sacador y otros parámetros geométricos, se establecen los 2.os y los modelos del mercado de cambios 3D (usando el ÁBACO). Un punto relevante de este trabajo es el uso de un algoritmo genético para optimizar los parámetros de red neuronal.

Desde un punto de vista general, este acercamiento permite el usar de modelos más flexibles y más exactos como entrada para el método de elemento finito, así que puede ser esperado una mejora en la calidad de los resultados enteros, aunque sea bien sabido que los errores en modelos de elemento finito vienen de varias fuentes. Su desventaja principal es que el proceso entero es largo, así que es muy difícil utilizar esta clase de modelo, como la función de la blanco u obstáculo, en la optimización de proceso que trabaja a máquina.

Método de elemento finito borroso.

El mercado de cambios clásico se ocupa de los problemas deterministas, es decir, problemas donde todos los datos y parámetros se saben con la precisión matemática. Sin embargo, el no-determinismo está generalmente presente en problemas de la vida real, especialmente en el modelado del proceso de fabricación. Este no-determinismo se puede clasificar ampliamente en variabilidad, donde están inherentes las variaciones al sistema físico modelado (por ejemplo, tolerancias de fabricación), y la incertidumbre que implica una deficiencia en el de proceso de modelado debido a una falta del conocimiento (e.g., relaciones constitutivas materiales en el comportamiento elástico-viscoplástico) [VER10]. Por otra parte, estos dos tipos de no-determinismo no se separan rígidos, y coinciden a menudo.

Varios acercamientos del mercado de cambios se han propuesto para considerar la borrosidad del conocimiento implicado en problemas prácticos. Cuando, para los datos implicados, se saben no sólo el intervalo respectivo pero también la distribución de probabilidad de estos intervalos, el mercado de cambios de probabilidad (o estocástico) puede ser aplicado. En este acercamiento se simulan todos los parámetros y, realizando un análisis estadístico, el valor de la probabilidad de los resultados se estiman [MUH06].

Sin embargo, en muchos usos del mundo real, no sólo el valor exacto real de un parámetro se sabe, pero también la información sobre la distribución de probabilidad del intervalo no está ningún disponible. Por ejemplo, la fuerza de producción de un grado de acero es obligada por los límites establecidos en el estándar respectivo. Sin embargo, la distribución de probabilidad depende de las características del proceso de fabricación, y es muy difícil ser estimado.

El mercado de cambios borroso fue desarrollado para ocuparse de esta clase de datos. El procedimiento para la ejecución de un análisis de elemento finito borroso se basa en un análisis de elemento finito determinista general. Empieza con la definición modelo, de la

cual las matrices de sistema borrosas están montadas. En la segunda parte del análisis, los conceptos de aritmética borrosa son aplicados para calcular los resultados del análisis de estas matrices de sistema borrosas.

Está claro que el mercado de cambios borroso tiene la capacidad potencial para ocuparse de la naturaleza no determinista de algunos fenómenos en proceso de fabricación. Sin embargo, al mejor de nuestro conocimiento, no se divulga trabajos sobre usar este acercamiento en el modelado del proceso de fabricación. En el contrario, se ha aplicado extensamente en diseño de ingeniería, especialmente en análisis estructural.

Sin embargo, podría ser esperado que, en un futuro próximo, el mercado de cambios borroso se convierta en un acercamiento acertado para modelar procesos de fabricación complejos, considerando condiciones más realistas y, de modo que, dando resultados más exactos.

Acercamientos para combinar el mercado de cambios y el AI en la optimización que trabaja a máquina.

FEM/AIO

Como en el modelado, en la optimización de procesos de fabricación hay varios acercamientos para combinar el mercado de cambios y el AI. La manera más intuitiva para esta combinación está usando un modelo de FEM/AI (véase a Fig. X.1) como funciones y/o apremios de la blanco. Esto es un acercamiento más completo porque no sólo utiliza las herramientas inteligentes para modelar algunos parámetros pero también el proceso de la optimización puede ser realizado empleando los métodos inteligencia-basados (técnicas generalmente matemáticas heurísticas).

Una representación gráfica general de este acercamiento se muestra en el higo X.3. Dos funciones de la blanco eran incluidas, aunque solamente una puede ser considerada, en un problema solo-objetivo de la optimización. Sin embargo, en vista de que dos o más funciones de la blanco son más apropiadas porque la utilización de las técnicas de optimización inteligentes es realmente eficiente al ocuparse de problemas con varios objetivos de la optimización.

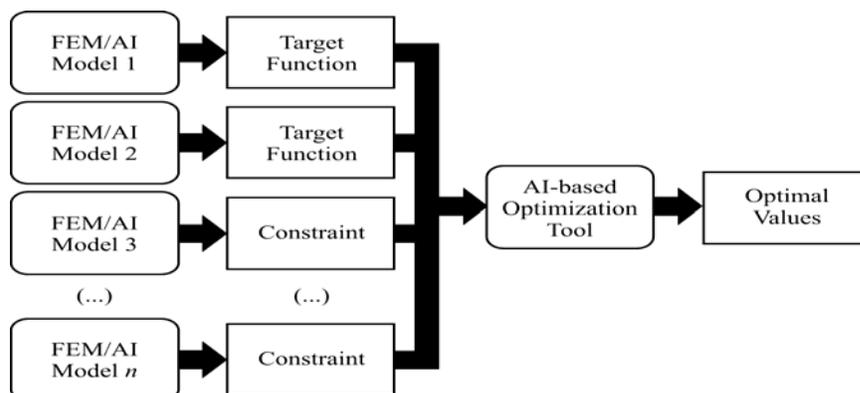


Figura X.3. Acercamiento de FEM/AI/AI para la optimización que trabaja a máquina.

Un ejemplo típico de este acercamiento fue publicado por Boillat y los compañeros de trabajo [BOI04]. En este papel un proceso seleccionado de la sinterización del láser del polvo titanio fue modelado usando una combinación de método del mercado de cambios no estándar y de diferencia finita. Después de eso, un modelo invertible fue obtenido por un Sugeno-tipo sistema de inferencia adaptante neuro-borroso. Finalmente, este modelo numérico invertible fue utilizado en una técnica de optimización iterativa para obtener la densidad más conveniente y la calidad de limitación de la partición manufacturada.

En otro acercamiento interesante [AZE10], el mercado de cambios y un algoritmo genético se combinan para optimizar el enfriamiento de un sistema del balanceo. En un primer paso, el modelo Mercado de cambios-basado predice temperatura y la tensión en el rollo, para diversos parámetros de proceso. Con estos valores, los modelos de regresión fueron cabidos. Finalmente, ambos objetivos (temperatura y tensión) son optimizados simultáneamente usando el algoritmo genético de no-clasificación II (NSGA-II).

Khoei y otros [KHO10] realiza un diseño óptimo para el proceso dado-acuciante del polvo basado en el acercamiento genético del algoritmo.

AI para la optimización que enreda del FE.

Finalmente, otra combinación propuesta interesante de mercado de cambios y de AI es la optimización que enreda. Ésta es una técnica de fines generales, que se puede aplicar no sólo al modelado de procesos de fabricación pero también a cualquier modelo Mercado de cambios-basado.

Bibliografía.

- [AZE10] AZENE Y.T., ROY R., FARRUGIA D., ONISA C., MEHNEN J., TRAUTMANN H., "Work roll cooling system design optimisation in presence of uncertainty and constrains", *CIRP Journal of Manufacturing Science and Technology*, In Press (Corrected), 2010, DOI: 10.1016/j.cirpj.2010.06.001.
- [BOI04] BOILLAT E., KOSOLOV S., GLARDON R., LOHER M., SALADIN D., LEVY G., "Finite element and neural network models for process optimization in selective laser sintering", *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, vol. 218 no. 6, 2004, p. 607-614.
- [CHA08] CHAN W.L., FU M.W., LU J., "An integrated FEM and ANN methodology for metal-formed product design", *Engineering Applications of Artificial Intelligence*, vol. 21 no. 8, 2008, p. 1170-1181.
- [DIT06] DITTMER J.P., JENSEN C.G., GOTTSCHALK M., ALMY T., "Mesh optimization using a genetic algorithm to control mesh creation parameters", *Computer-Aided Design and Applications*, vol. 3 no. 6, 2006, p. 731-740.
- [DIX08] DIXIT P.M., DIXIT U.S., *Modeling of metal forming and machining processes by finite element and soft computing methods*, Engineering Materials and Processes, London (UK), Springer-Verlag, 2008, ISBN 978184800188.
- [DOD04] DODIER R.H., HENZE G.P., "Statistical analysis of neural networks as applied to building energy prediction", *Journal of Solar Energy Engineering*, vol. 126 no. 1, 2004, p. 592-600.
- [FU10] FU Z., MO J., CHEN L., CHEN W., "Using genetic algorithm-back propagation neural network prediction and finite-element model simulation to optimize the process of multiple-step incremental air-bending forming of sheet metal", *Materials and Design*, vol. 31 no. 1, 2010, p. 267-277.
- [GUD08] GUDUR P.P., DIXIT U.S., "A neural network-assisted finite element analysis of cold flat rolling", *Engineering Applications of Artificial Intelligence*, vol. 21 no. 1, 2008, p. 43-52.
- [HAS04] HASHASH Y.M.A., JUNG S., GHABOUSSI J., "Numerical implementation of a neural network based material model in finite element analysis", *International Journal for Numerical Methods in Engineering*, vol. 59 no. 7, 2004, p. 989-1005.
- [HU02] HU Y.H., HWANG J.-N., *Handbook of neural network signal processing*, Boca Raton, FL (USA), CRC Press, 2002, ISBN 0849323592.
- [JAV03] JAVADI A.A., TAN T.P., ZHANG M., "Neural network for constitutive modelling in finite element analysis", *Journal of Computer Assisted Mechanics and Engineering Sciences*, vol. 10 no. 4, 2003, p. 523-529.
- [KIM00] KIM D.J., KIM B.M., "Application of neural network and FEM for metal forming processes", *International Journal of Machine Tools and Manufacture*, vol. 40 no. 6, 2000, p. 911-925.
- [LIN04] LIN F.C., KWAN C.T., "Application of abductive network and FEM to predict an acceptable product on T-shape tube hydroforming process", *Computers Structures*, vol. 84 no. 15-16, 2004, p. 1189-1200.
- [LIN05] LIN Y.-Y., LO S.-P., "Modeling of chemical mechanical polishing process using FEM and abductive network", *Engineering Applications of Artificial Intelligence*, vol. 18 no. 3, 2005, p. 373-381.
- [MAN06] MANABE K.-i., SUETAKE M., KOYAMA H., YANG M., "Hydroforming process optimization of aluminum alloy tube using intelligent control technique", *International Journal of Machine Tools and Manufacture*, vol. 46 no. 11, 2006, p. 1207-1211.

- [MOE__] MOENS D., VANDEPITTE D., TEICHERT W., Application of the fuzzy finite element method in structural dynamics, .
- [MOH07] MOHAMMADI F., KASHANIZADE H., MOSAVI MASHADI M., "Optimization using finite element analysis, neural network, and experiment in tube hydroforming of aluminium T joints", *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, vol. 221 no. 8, 2007, p. 1299-1305.
- [MUH06] MUHANNA R., KREINOVICH V., SOLÍN P., CHESSA J., ARAIZA R., XIANG G., Interval finite element methods: New directions, 2006.
- [RAY04] RAY P., MACDONALD B.J., "Determination of the optimal load path for tube hydroforming processes using a fuzzy load control algorithm and finite element analysis", *Finite Elements in Analysis and Design*, vol. 41 no. 2, 2004, p. 173-192.
- [SHA07] SHA W., EDWARDS K.L., "The use of artificial neural networks in materials science based research", *Materials and Design*, vol. 28 no. 6, 2007, p. 1747-1752.
- [SHA09a] SHARMA R.S., UPADHYAY V., RAJ K.H., "Neuro-fuzzy modeling of hot extrusion process", *Indian Journal of Engineering and Material Sciences*, vol. 16 no. 2, 2009, p. 86-92.
- [SHA09b] SHAHANI A.R., SETAYESHI S., NODAMAIE S.A., ASADI M.A., REZAIIE S., "Prediction of influence parameters on the hot rolling process using finite element method and neural network", *Journal of Materials Processing Technology*, vol. 209 no. 4, 2009, p. 1920-1935.
- [SUN10] SUN Y., ZENG W.D., ZHAO Y.Q., QI Y.L., MA X., HAN Y.F., "Development of constitutive relationship model of Ti600 alloy using artificial neural network", *Computational Materials Science*, vol. 48 no. 3, 2010, p. 686-691.
- [UMB07] UMBRELLO D., AMBROGIO G., FILICE L., SHIVPURI R., "An ANN approach for predicting subsurface residual stresses and the desired cutting conditions during hard turning", *Journal of Materials Processing Technology*, vol. 189 no. 1, 2007, p. 143-152.
- [UMB08] UMBRELLO D., AMBROGIO G., FILICE L., SHIVPURI R., "A hybrid finite element method-artificial neural network approach for predicting residual stresses and the optimal cutting conditions during hard turning of AISI 52100 bearing steel", *Materials and Design*, vol. 29 no. 4, 2008, p. 873-883.
- [VER10] VERHAEGHE W., DE MUNCK M., DESMET W., VANDEPITTE D., MOENS D., "A fuzzy finite element analysis technique for structural static analysis based on interval fields", REC, 2010.
- [ZHA08] ZHANG Y., ZHAO S., ZHANG Z., "Optimization for the forming process parameters of thin-walled valve shell", *Thin-Walled Structures*, vol. 46 no. 4, 2008, p. 371-379.