

# Estudio comparativo de dos sistemas de monitorización del desgaste de la herramienta y de la rugosidad superficial basados en LS-SVM y redes neuronales

**D. Rodríguez Salgado<sup>(1)</sup>, I. Cambero Rivero<sup>(1)</sup>, J.M. Herrera Olivenza<sup>(1)</sup>, P.J. Núñez López<sup>(2)</sup>,  
E. García Plaza<sup>(2)</sup>**

*(1) Dpto. de Ingeniería Mecánica, Energética de y de los Materiales. Universidad de Extremadura  
drs@unex.es*

*(2) Dpto. Mecánica Aplicada e Ingeniería de Proyectos. Universidad de Castilla La Mancha*

---

*Los sistemas de monitorización del desgaste de la herramienta (VB) y de la rugosidad superficial (Ra) están siendo ampliamente estudiados con el objetivo de conseguir el denominado mecanizado desatendido. En este artículo se analizan dos sistemas de monitorización de estos parámetros mediante dos técnicas de predicción que han demostrado ser interesantes para estas aplicaciones y que son: el método Least-Square Support Vector Machine (LS-SVM) y las redes neuronales (RN). Las señales monitorizadas son las vibraciones en las direcciones de avance y radial y la intensidad de corriente consumida por el motor de avance del torno en ambos sistemas. Antes de predecir los dos parámetros VB y Ra, las señales monitorizadas son previamente procesadas para extraer la información más correlacionada con estos parámetros. Los resultados de ambos sistemas son perfectamente válidos, consiguiéndose alta precisión y robustez en la estimación realizada de VB y Ra con ambos sistemas. Los errores medios cuadráticos obtenidos con ambos métodos son muy similares, por tanto la principal diferencia radica en el tiempo de computación, ya que LS-SVM consume menos tiempo que la RN y por tanto su empleo para realizar sistemas de monitorización on-line son muy interesantes.*

---

## 1. INTRODUCCIÓN

La industria se dirige hacia lo que se ha venido denominando el mecanizado desatendido con el objetivo de aumentar la productividad, la fiabilidad del proceso y lógicamente para reducir costes de fabricación. Para conseguir un mecanizado desatendido es necesario tener completamente automatizado el proceso de mecanizado, incluyendo un sistema de monitorización y predicción del desgaste de la herramienta que permita retirarla en el momento justo, es decir, antes de que exceda su umbral de desgaste (que para mecanizados de acabado se suele fijar en  $VB = 0.2\text{mm}$ ) y no mucho antes de aproximarse a dicho umbral para que se amortice el coste de dicha herramienta y el tiempo dedicado a cambios de herramienta también sea el menor posible. Lógicamente también debe cambiarse la herramienta antes de que su degradación implique superar el umbral fijado para  $Ra$ . Todo esto debe hacerse además cumpliendo la máxima impuesta en el mercado desde hace varios años y es que la tasa de defectos en las piezas fabricadas tiene que ser cero.

Puede intuirse que este objetivo a nivel industrial y cuya resolución recae en gran parte en la comunidad científica, no es un reto sencillo de conseguir, pues como es bien conocido los procesos de mecanizado dependen de un gran número de variables que hacen que su control total todavía no se haya logrado. No obstante, esto supone a su vez un reto de investigación muy interesante que ha conseguido que en los últimos 20 años y sobre todo en la última década se hayan incrementado notablemente tanto los grupos de investigación internacionales que se dedican a trabajar en este tema, como el número de publicaciones en revistas de impacto [1-12]. En concreto, muchos de estos trabajos se han centrado en el desarrollo de sistemas de monitorización del desgaste de la herramienta y la rugosidad superficial, aunque bien es cierto que en general se han tratado por separado [13-17]. El principal objetivo de todos estos trabajos es el de conseguir un sistema capaz de predecir en

tiempo real el desgaste de la herramienta, normalmente el desgaste del flanco, por su relación con la calidad superficial obtenida en la pieza mecanizada; y en estimar la rugosidad superficial, normalmente la rugosidad media aritmética ( $R_a$ ). En este sentido es importante destacar que al analizar los trabajos publicados [1-19, 21-22] es sencillo comprobar que aunque se consiguen buenos resultados en relación con la exactitud y fiabilidad de los sistemas de monitorización diseñados, sin embargo, las señales procesadas para obtener información del proceso no son siempre las mismas para la estimación del desgaste y la rugosidad superficial, o bien siendo las mismas, el procesado de dicha señal puede ser distinto según se desee estimar uno u otro parámetro.

Esto supone un lastre para la industria ya que requeriría del diseño de un sistema de monitorización con multitud de señales o con un tiempo de procesado de señales elevado para la estimación de ambos parámetros de forma simultánea. Actualmente se ha llegado por consenso en la comunidad científica a determinar ciertos criterios que deben cumplir los sistemas de monitorización propuestos y que son:

- Un equilibrio entre el número de sensores utilizados, su coste, y la eficiencia y efectividad del sistema de monitorización.
- Un tiempo de cálculo (procesado de señales monitorizadas y estimación de  $VB$  y/o  $R_a$ ) suficientemente reducido que permite cambiar la herramienta antes de que el desgaste o la rugosidad superen su correspondiente umbral.
- El uso de sensores que no perturben el mecanizado.

En este artículo se presentan dos sistemas de monitorización diferenciados únicamente por el método empleado en la estimación de  $VB$  y  $R_a$  en función de las señales monitorizadas. Estas señales son las vibraciones en las direcciones de avance y corte y la intensidad consumida por el motor de avance del torno y que se ha empleado para estimar la fuerza en dicha dirección. Ambos sistemas se han diseñado de modo que se verifiquen los requisitos anteriores para su adecuada implantación en la industria.

## 2. SEÑALES MONITORIZADAS

El análisis de las señales monitorizadas es determinante en el desarrollo de un sistema de monitorización del desgaste de la herramienta y la rugosidad superficial, ya que de ello depende en gran medida la eficacia del sistema diseñado. En este sentido, otra cuestión a tener en cuenta es el coste de los sensores utilizados. Esto es sin duda, un factor decisivo para que el sistema de monitorización sea económicamente viable y por lo tanto aplicable en la práctica. Ambos factores han determinado las señales de control elegidas para el diseño del sistema propuesto.

A continuación se describen las técnicas de procesado que se han empleado para el análisis de la información que estas señales incorporan respecto de los parámetros objetivos  $VB$  y  $R_a$ .

### 2.1. Intensidad de corriente

El coste de un dinamómetro es bastante alto por ello, en este trabajo se ha utilizado la corriente consumida por el motor de avance para estimar la fuerza de corte en dicha dirección. Varios trabajos [17-19] han estudiado la forma de estimar las fuerzas de corte en función de la corriente consumida por los motores. Estos trabajos concluyen que la fuerza de avance puede ser estimada en función de la velocidad de avance ( $f_r$ ) y la diferencia entre la intensidad ( $\Delta I$ ) consumida por el motor durante el mecanizado ( $I$ ) y el consumo para esa misma velocidad en vacío ( $I_0$ ). Matemáticamente esta relación se puede expresar como sigue:

$$F_f = h(\Delta I, f_r) \quad (1)$$

El valor  $\Delta I$  puede calcularse fácilmente, ya que puede ser medido durante el mecanizado en los experimentos y es función de la velocidad de avance. Se ha encontrado que, en un nivel de confianza del 94,7%,  $I_0$  (A) varía linealmente con  $f_r$  (mm/min) de acuerdo con:

$$I_0 = -0.0007 \cdot f_r + 0.3378 \quad (2)$$

y que  $f_r$  (mm/min) se puede expresar como una función lineal de la frecuencia (Hz):

$$f_r = 0.3488f \quad (3)$$

Con estas expresiones la fuerza de avance se puede estimar una vez que la expresión de la función  $h$  (ecuación 1) se ha determinado. En este trabajo, en lugar de buscar una expresión matemática para la función  $h$ , la relación entre la fuerza de avance  $F_f$  y los valores  $\Delta I$  y  $f_r$ , ha sido establecido por una red neuronal o el método LS-SVM entrenados para este propósito. En la figura 1 se muestra, en el lado izquierdo, la información presentada a la red  $NN_1$  y al método LS-SVM<sub>1</sub> según el sistema de monitorización para estimar la fuerza de avance. La salida de esta red, es decir, la fuerza de avance estimada, se utiliza como entrada a otra red neuronal  $NN_2$  o LS-SVM<sub>2</sub> que se introduce en el sistema de monitorización propuesto para estimar el desgaste de la herramienta y rugosidad superficial (ver figura 1).

## 2.2. Vibraciones

Para aumentar la precisión de la estimación del desgaste de la herramienta en el flanco, y especialmente para obtener una alta precisión y fiabilidad en la estimación de la rugosidad superficial, la vibración en las direcciones de avance y radial se han introducido como inputs del sistema. Estas señales fueron procesadas usando una técnica conocida como Singular Spectrum Analysis (SSA). SSA es una técnica no-paramétrica de análisis de series temporales que se fundamenta en principios de la estadística multivariante. El método SSA construye una matriz, llamada "matriz de trayectoria" de la serie original en un proceso llamado "embedding". La matriz de trayectoria se somete posteriormente a una descomposición de valor singular (SVD). En este paso, el método calcula los valores propios de una matriz construida con la matriz de trayectoria. Cada una de estas matrices se puede transformar en una serie temporal reconstruida por un proceso llamado "promedio diagonal". Las series reconstruidas a partir de cada matriz primaria se conocen como "componentes principales" [20]. La suma de todas las componentes principales es igual a la serie temporal original. Una explicación más detallada del método se puede encontrar en [21-22].

En este trabajo se ha utilizado la descomposición SSA de las señales de vibración como valores significativos de desgaste de la herramienta y la rugosidad con una longitud de ventana de  $L=5$ , y por tanto, con una descomposición de la señal en 5 autovalores y 5 componentes principales.

## 3. MÉTODOS DE ESTIMACIÓN

Para la estimación del desgaste y la rugosidad en función de los inputs del sistema (parámetros procesados de las señales monitorizadas y condiciones de corte de la figura 1) se han implementado los métodos que se describen a continuación para posteriormente compararlos.

### 3.1. Least-square support vector machine LS-SVM

La técnica LS-SVM es una versión reformulada de la SVM. La principal ventaja de LS-SVM (que es computacionalmente más eficiente que el método SVM estándar) es que sólo requiere la solución de un conjunto de ecuaciones lineales en lugar del problema de programación cuadrática que implica SVM.

El objetivo es construir una función  $y = f(x)$  que representa la dependencia de la salida  $y_i$  en la entrada  $X_i$ . El modelo LS-SVM es de la forma siguiente:

$$y = \mathbf{w}^T \varphi(x) + b \quad (4)$$

donde  $\mathbf{w}$  es el vector de peso y  $b$  es el término de sesgo. En el presente trabajo, esta función se construye con la entrada  $x_i$  que representa la información que se introduce como inputs y  $y_i$  representa el/los parámetro/s estimado/s. Este modelo de regresión se puede construir

usando una función de mapeo  $\varphi(\bullet)$  no lineal. El problema de optimización y las restricciones de igualdad se definen por las siguientes ecuaciones:

$$\min J(\mathbf{w}, \mathbf{e}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (5)$$

sueto a:

$$y_i = \mathbf{w}^T \varphi(\mathbf{X}_i) + b + e_i, \quad i = 1, \dots, N \quad (6)$$

donde  $e_i$  es el error aleatorio y  $C \in R^+$  es un parámetro de regularización o compromiso en la optimización entre la minimización de los errores de entrenamiento y la complejidad del modelo.

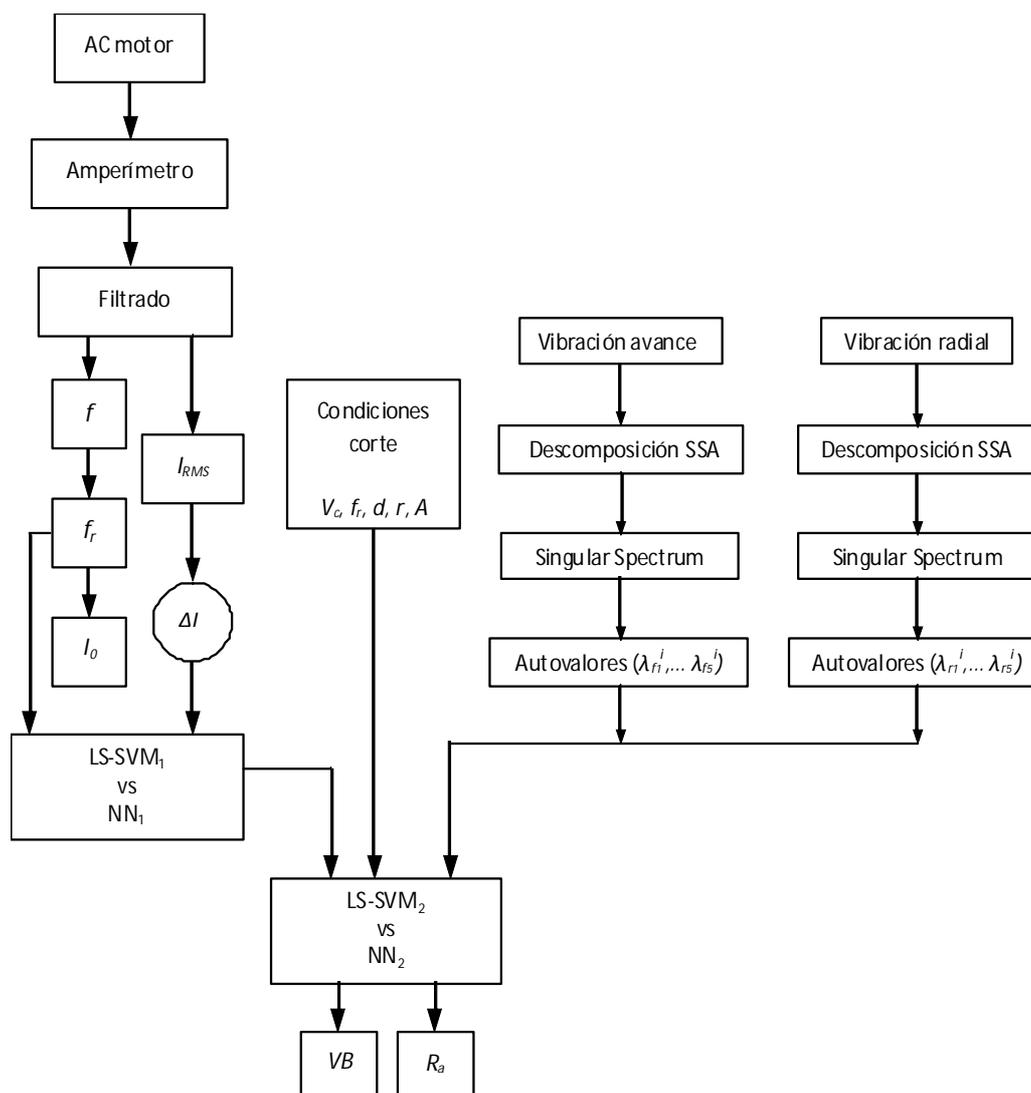


Figura 1. Esquema del sistema de monitorización propuesto con indicación de la información que emplean los métodos de estimación requeridos para este sistema

El objetivo ahora es encontrar los parámetros óptimos que minimizan el error de predicción del modelo de regresión (4). El modelo óptimo se elegirá al minimizar la función de coste (5) donde los errores  $e_i$  son mínimos. Esta formulación corresponde a la regresión en el espacio de características y, dado que la dimensión del espacio característica es alta, posiblemente infinita, este problema es difícil de resolver. Por lo tanto, para resolver este problema de optimización, se construye la siguiente función de Lagrange:

$$L(\mathbf{w}, b, \mathbf{e}, \boldsymbol{\alpha}) = J(\mathbf{w}, \mathbf{e}) - \sum_{i=1}^N \alpha_i \{ \mathbf{w}^T \varphi(\mathbf{X}_i) + b + e_i - y_i \} \quad (7)$$

where  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]$  son los multiplicadores de Lagrange. La solución de la ecuación (7) puede obtenerse por diferenciación respecto a  $w$ ,  $b$ ,  $e_i$ , and  $\alpha_i$ :

$$\begin{aligned} \frac{\partial L}{\partial w} = 0 &\rightarrow w = \sum_{i=1}^N \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 &\rightarrow \sum_{i=1}^N \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 &\rightarrow \alpha_i = C e_i, \quad i = 1, \dots, N \\ \frac{\partial L}{\partial \alpha_i} = 0 &\rightarrow \mathbf{w}^T \varphi(\mathbf{X}_i) + b + e_i - y_i = 0, \quad i = 1, \dots, N \end{aligned}$$

Estas ecuaciones pueden ser escritas en forma matricial de la forma:

$$\begin{bmatrix} 0 & \vec{1}^T \\ \vec{1} & \mathbf{\Omega} + C^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{I} \end{bmatrix} \quad (8)$$

donde  $\Omega_{ij} = K(\mathbf{x}_i, \mathbf{x}_j) = \varphi^T(\mathbf{x}_i) \varphi(\mathbf{x}_j)$ , para  $j = 1, \dots, N$ , siendo  $K(\mathbf{x}_i, \mathbf{x}_j)$  la función Kernel y  $\mathbf{\Omega}$  la matriz de kernel. Finalmente, los valores estimados de  $b$  y  $\alpha_i$ , pueden obtenerse mediante la resolución del sistema de ecuaciones lineales de la ecuación (8), y el modelo resultante LS-SVM puede ser expresado como:

$$y = f(x) = \sum_{i=1}^N \hat{\alpha}_i K(x, x_i) + \hat{b} \quad (9)$$

En este trabajo se ha elegido la función kernel (RBF) que es:

$$K(x, x_i) = \exp\left(\frac{-1}{2\sigma^2} \|x - x_i\|^2\right) \quad (10)$$

donde  $\sigma$  es el factor de escala para el ajuste. En comparación con algunas otras funciones kernel, el RBF es capaz de acortar el proceso de convergencia computacional y mejorar el rendimiento de LS-SVM, una característica de gran importancia en el diseño de un sistema de predicción del desgaste de la herramienta y de la rugosidad superficial para su aplicación práctica.

### 3.2. Redes neuronales

En relación con la elección del tipo de red neuronal artificial implementada para el desarrollo de este sistema, se ha empleado una red neuronal multicapa. El modelo de red neuronal que se propone en este estudio es el perceptrón multicapa, formado por una capa de entrada, una capa oculta y una capa de salida. La red se entrenó aplicando un algoritmo del tipo "backpropagation" que emplea una optimización por mínimos cuadrados para minimizar la diferencia entre las salidas y los valores del entrenamiento, optimizando de este modo los pesos. Las funciones de activación se han elegido lineales.

## 4. ENSAYOS

En el experimento llevado a cabo se mecanizó acero C45. El rango de condiciones de mecanizado en el proceso de corte ha sido el recomendado por el fabricante de las herramientas (TiN, carburo recubierto). Para detectar el estado de la herramienta en el proceso de torneado se han utilizado dos acelerómetros situados próximos a la herramienta. Las señales de los dos acelerómetros fueron procesadas y almacenadas mediante un sistema de adquisición de datos. Las señales de vibración se muestrearon a una frecuencia de 10 kHz durante un periodo de 150 ms. En la tabla 1 se relacionan todos los parámetros e instrumentación del experimento. La tabla 2 muestra todos los ensayos realizados y la tabla 3 los ensayos utilizados para evaluar los sistemas de monitorización propuestos.

Cutting speed ( <i>vc</i> )	90-180 (m/min)
Feed rate ( <i>fr</i> )	0.05-0.2 (mm/rev)
Depth of cut ( <i>d</i> )	0.5-1 (mm)
Tool insert	CCMT 120404, CCMT 120408, TCMT 110204, VCMT 160404, VCMT 160408
Tool holder	PCLN 25 61
Tool flank wear ( <i>VB</i> )	0-250 ( $\mu\text{m}$ )
Machine tool	Pinacho R180

Tabla 1. Posición, velocidad y aceleración angulares del sólido 1

## 5. RESULTADOS

En total se han realizado 40 ensayos en los que se obtuvieron las distintas señales monitorizadas. Con todos estos ensayos se ha desarrollado el sistema de monitorización de modo que una parte de estos ensayos se ha empleado en el entrenamiento del sistema y otros se han empleado únicamente en su evaluación (experimentos de la tabla 3).

Como se muestra en estas tablas se han realizado experimentos en los que se han variado tanto las velocidades de corte (*vc*), como la velocidad de avance (*fr*), la profundidad de pasada (*d*) y el ángulo de la punta de la herramienta (*A*) y el radio de la punta (*r*).

A continuación se detallan los errores obtenidos cuando el sistema de monitorización se diseñó con redes neuronales para realizar la estrategia de predicción y cuando se hizo implementando los sistemas de predicción basados en LS-SVM.

### 5.1. Estimación con redes neuronales

Para determinar la arquitectura óptima de las redes neuronales cuando el sistema se diseña de modo que la estrategia de predicción queda resuelta por las redes  $NN_1$  y  $NN_2$ , como se muestra en la figura 1, se fijó el número máximo de iteraciones en 20.000 para su convergencia y posteriormente se calcularon los errores. De este modo se ha determinado que la arquitectura óptima para la red  $NN_1$  es 2-1-1 y para la red  $NN_2$  esta arquitectura fue 16-5-2, siendo 16 los parámetros de entrada (5 parámetros de corte y 11 parámetros obtenidos de las señales monitorizadas, figura 1). Todos estos resultados se obtuvieron con los experimentos utilizados para el entrenamiento del sistema, es decir, todos los experimentos de la tabla 2 exceptuando los experimentos reservados para la validación de ambos sistemas, y que son los que se detallan en la tabla 3.

El error cuadrático medio que se obtuvo en la estimación de la rugosidad media fue de 0.21 mientras que el error en la estimación del desgaste fue de 8.25  $\mu\text{m}$ .

### 5.2. Estimación con LS-SVM

Para el entrenamiento de los sistemas LS-SVM<sub>1</sub> y LS-SVM<sub>2</sub> se ha seguido el mismo planteamiento que se ha detallado en el apartado anterior, es decir, se han empleado los datos de la tabla 2 exceptuando aquellos que aparecen en la tabla 3. En este caso los errores cuadráticos medios obtenidos en la estimación de la rugosidad una vez que el sistema fue entrenado y por tanto fijados los estimadores de los dos sistemas LS-SVM<sub>1</sub> y LS-SVM<sub>2</sub> fueron de 0.23 para la calidad superficial y de 7.57  $\mu\text{m}$  para el desgaste del flanco de la herramienta.

Nº Exp.	vc (m/min)	fr (mm/rev)	d (mm)	A (mm)	VB (µm)	Replicates Ra (µm)			$\bar{R}_a$
1	90	0.05	0.5	80	87	1.96	1.69	1.77	1.81
2	90	0.05	1	35	121	2.01	1.76	1.87	1.88
3	90	0.125	0.5	35	53	1.59	1.79	1.87	1.75
4	90	0.05	1	80	25	1.81	1.64	1.77	1.74
5	90	0.05	0.5	80	94	1.68	1.53	1.64	1.62
6	90	0.125	1	60	109	1.39	1.62	1.61	1.54
7	90	0.05	0.5	35	215	2.14	1.95	2.11	2.07
8	90	0.125	0.5	60	123	1.43	1.68	1.57	1.56
9	110	0.125	0.5	60	174	1.55	1.52	1.37	1.48
10	110	0.20	1	80	127	3.58	3.24	3.29	3.37
11	110	0.125	0.5	35	96	1.76	1.65	1.78	1.73
12	110	0.125	0.5	35	194	1.88	1.99	1.89	1.92
13	110	0.20	0.5	35	59	4.57	4.75	5.12	4.81
14	110	0.125	1	60	28	1.79	1.73	1.91	1.81
15	110	0.05	1	35	56	1.21	1.49	1.10	1.27
16	110	0.125	0.5	35	114	1.52	1.68	1.54	1.58
17	130	0.125	0.5	80	165	1.57	1.50	1.36	1.48
18	130	0.125	1	35	37	1.71	1.69	1.83	1.74
19	130	0.05	0.5	80	210	1.24	1.27	1.35	1.29
20	130	0.05	1	80	131	1.67	1.44	1.74	1.62
21	130	0.05	0.5	60	156	0.93	1.02	0.97	0.97
22	130	0.125	1	35	85	1.70	1.78	1.42	1.63
23	130	0.05	0.5	60	144	0.72	1.05	0.90	0.89
24	130	0.125	0.5	35	78	1.63	1.75	1.70	1.69
25	160	0.125	0.5	60	28	1.15	0.90	0.98	1.01
26	160	0.20	1	35	185	3.12	3.46	3.98	3.52
27	160	0.125	0.5	60	26	1.07	1.18	1.02	1.09
28	160	0.05	0.5	35	152	1.32	1.27	1.17	1.25
29	160	0.05	1	80	59	1.22	1.35	1.61	1.39
30	160	0.125	1	60	82	1.21	1.14	1.32	1.22
31	160	0.05	0.5	35	119	0.72	1.00	0.92	0.88
32	160	0.125	0.5	35	153	1.12	1.19	1.21	1.17
33	180	0.20	0.5	60	88	1.12	0.95	1.15	1.07
34	180	0.125	1	80	34	1.01	0.97	1.07	1.02
35	180	0.125	1	35	74	1.38	1.57	1.41	1.45
36	180	0.20	1	60	94	2.77	2.98	2.85	2.87
37	180	0.20	0.5	80	174	3.25	3.01	3.10	3.12
38	180	0.125	0.5	60	162	1.12	1.35	1.45	1.31
39	180	0.125	1	35	37	1.70	1.62	1.40	1.57
40	180	0.125	0.5	35	55	1.34	1.43	1.39	1.39

Tabla 2. Ensayos realizados

## 6. CONCLUSIONES

En este trabajo se ha estudiado la monitorización del desgaste de la herramienta y del acabado superficial empleando dos señales de vibración y la corriente consumida por el motor de avance para estimar la fuerza en dicha dirección y emplearla como input en el sistema de predicción de VB y Ra. Con todos los inputs del sistema (figura 1) se han desarrollado dos sistemas que difieren únicamente en los métodos empleados para la

estimación tanto de la fuerza de avance en función de los datos obtenidos de la corriente consumida, como en la estimación de los parámetros objetivo (rugosidad y desgaste) en función de todos los inputs del sistema y de la fuerza de avance predicha. Esto es, un sistema es el que se representa en la figura 1 cuando se emplean las redes neuronales y otro sistema de monitorización es el que teniendo el mismo esquema de la figura 1 emplea el método LS-SVM para la predicción tanto de la fuerza de avance como de  $VB$  y  $R_a$ .

Nº Exp.	vc (m/min)	fr (mm/rev)	d (mm)	A (mm)	VB ( $\mu\text{m}$ )	$\bar{R}_a$
1	90	0.05	0.5	80	87	1.81
3	90	0.125	0.5	35	53	1.75
7	90	0.05	0.5	35	215	2.07
12	110	0.125	0.5	35	194	1.92
17	130	0.125	0.5	80	165	1.48
22	130	0.125	1	35	85	1.63
25	160	0.125	0.5	60	28	1.01
29	160	0.05	1	80	59	1.39
32	160	0.125	0.5	35	153	1.17
35	180	0.125	1	35	74	1.45
37	180	0.20	0.5	80	174	3.12
40	180	0.125	0.5	35	55	1.39

Tabla 3. Ensayos utilizados para evaluar los sistemas de monitorización propuestos

Los resultados obtenidos tanto en la estimación de la rugosidad superficial como del desgaste por ambos sistemas permite concluir que, tanto la fiabilidad como la precisión de ambos sistemas para un mismo número de datos ensayos empleados en el entrenamiento como en la validación de los sistemas, son muy similares. Puede destacarse que la red neuronal obtiene un valor ligeramente mejor en el rmse de la rugosidad superficial y que por el contrario en la estimación del desgaste el menor rmse lo obtiene el método LS-SVM. En cualquier caso, las diferencias obtenidas en ambos rmse no son lo suficientemente significativas como para concluir que un método es mejor que el otro para la estimación de estos parámetros y por tanto para su empleo en el desarrollo de sistemas de monitorización del desgaste del flanco y/o de la rugosidad superficial en procesos de torneado.

Algunas otras conclusiones que se derivan de este estudio se pueden resumir en los siguientes puntos:

- La descomposición SSA de las vibraciones, es decir, los autovalores de los espectros obtenidos mediante SSA de las vibraciones, proporcionan información muy valiosa para su uso en la estimación de la rugosidad superficial.
- La precisión de un sistema de predicción de la rugosidad superficial basado en las vibraciones de corte puede mejorarse mediante la inclusión de información relativa a la geometría de la herramienta de corte. Esto se ha comprobado al no introducir en el sistema los valores del ángulo de la herramienta ni su radio de la punta, obteniéndose valores similares en los rmse de la estimación del desgaste pero valores superiores del rmse en la estimación de la rugosidad, es decir, una peor estimación.
- Los resultados muestran que el método de estimación basado en LS-SVM es perfectamente adecuado para la estimación de la rugosidad y del desgaste del flanco de la herramienta en procesos de torneado.
- Los tiempos de computación son 2,5 segundos de media inferiores en LS-SVM que en el sistema que emplea redes neuronales. Por tanto, si el conjunto de datos de entrenamiento del sistema representa todo el rango de parámetros en los que se le

solicitará la estimación de  $VB$  y  $Ra$ , puede ser un sistema muy interesante para la industria por su mayor agilidad.

## 7. REFERENCIAS

- [1] J. Jurkovic, M. Korosec, J. Kopac, New approach in tool wear measuring technique using CCD vision system, *Int J Mach Tools Manuf.* 45(9) (2005), 1023–1030.
- [2] N. Ghosh, Y.B. Ravi, A. Patra, S. Mukhopadhyay, S. Paul, A.R. Mohanty, A.B. Chattopadhyay, Estimation of tool wear during CNC milling using neural network-based sensor fusion, *Mechanical Systems and Signal Processing* 21(1) (2007), 466–479.
- [3] C. Scheffer, H. Kratz, P.S. Heyns, F. Klocke, Development of a tool wear monitoring system for hard turning, *Int J Mach Tools Manuf.* 43(10) (2003), 973–985.
- [4] R.E. Haber, J.E. Jimenez, C.R. Peres, J.R. Alique, An investigation of tool wear monitoring in a high-speed machining process, *Sensors and Actuators A: Physical* 116(3) (2004), 539–545.
- [5] R.G. Silva, K.J. Baker, S.J. Wilcox, The adaptability of a tool wear monitoring system under changing cutting conditions, *Mechanical Systems and Signal Processing* 14(2) (2000), 287–298.
- [6] C. Scheffer, P.S. Heyns, An industrial tool wear monitoring system for interrupted turning, *Mech Systems and Signal Processing* 18 (2004), 1219–1242.
- [7] L.A. Franco-Gasca, G. Herrera-Ruiz, R. Peniche-Vera, R.J. Romero-Troncoso, W. Leal-Tafolla, Sensorless tool failure monitoring system for drilling machines, *Int J Mach Tools Manuf.* 46(3–4) (2006), 381–386.
- [8] K. Niranjan Prasad, B. Ramamoorthy, Monitoring of flank wear of coated tools in high speed machining with a neural network ART2, *Int J Mach Tools Manuf.* 44(12–13) (2004), 1311–1318.
- [9] I. Abu-Mahfouz, Drilling wear detection and classification using vibration signals and artificial neural network, *Int J Mach Tools Manuf.* 43(7) (2003), 707–720.
- [10] K. Jemielniak, Tool wear monitoring based on a non-monotonic signal feature, *Proc IMechE J Eng Manufacture* 220(2) (2006), 163–170.
- [11] Ch. Srinivasa Rao, R.R. Srikant, Tool wear monitoring—an intelligent approach, *Proc IMechE J Eng Manufacture* 218(8) (2004), 905–912.
- [12] S. Das, R. Islam, A.B. Chattopadhyay, A simple approach for on-line tool wear monitoring using the analytic hierarchy process, *Proc. IMechE J Eng Manufacture* 211(1) (1997), 19–27.
- [13] S.N. Huang, K.K. Tan, Y.S. Wong, C.W. de Silva, H.L. Goh, W.W. Tan, Tool wear detection and fault diagnosis based on cutting force monitoring, *Int J Mach Tools Manuf.* 47(3–4) (2007), 444–451.
- [14] W. Lia, W. Gong, T. Obikawab, Y.A. Shirakashic, A method of recognizing tool-wear states based on a fast algorithm of wavelet transform, *J Mater Process Technol* 170(1–2) (2005), 374–380.
- [15] C. Chungchoo, D. Saini, On-line tool wear estimation in CNC turning operations using fuzzy neural network model, *Int J Mach Tools Manuf.* 42(1) (2002), 29–40.

- 
- [16] G. Byrne, D. Dornfeld, I. Inasaki, G. Ketteler, W. König, R. Teti, Tool condition monitoring—status of research and industrial application, *Ann. CIRP* 44(2) (1995), 541–657.
- [17] T.Y. Kim, J. Kim, Adaptive cutting force control for a machining centre by using indirect cutting force measurements, *Int J Mach Tools Manuf.* 36(8) (1996), 925–937.
- [18] X. Li, Real-time tool condition monitoring in turning, *International Journal of Production Research* 39(5) (2001), 981–992.
- [19] X. Li, Development of current sensor for cutting force measurement in turning, *IEEE Transactions on Instrumentation and Measurement* 54 (2005), 289–296.
- [20] N. Golyandina, V. Nekrutkin, A. Zhigljavsky, *Analysis of Time Series Structure—SSA and Related Techniques*, Chapman & Hall, (2001).
- [21] D.R. Salgado, F.J. Alonso, Tool wear detection in turning operations using singular spectrum analysis, *J Mater Process Technol* 171(3) (2006), 451–458.
- [22] D.R. Salgado, F.J. Alonso, An approach based on current and sound signals for in-process tool wear monitoring, *Int J Mach Tools Manuf.* 47 (2007), 2140–2152.