

**UNIVERSIDAD NACIONAL DE GENERAL SAN MARTIN
COMISION NACIONAL DE ENERGIA ATOMICA
INSTITUTO DE TECNOLOGIA
“Prof. Jorge A. Sábato”**

**“Estudio de procesos de maquinado mediante el análisis
de señales de emisión acústica durante el corte”**

Por Ing. Guido C. Ferrari

Directores

Dr. Martín P. Gómez

Dr. José E. Ruzzante

()Tesis para optar por el título de Magister en Ciencia y Tecnología de
Materiales.*

República Argentina

2014

Agradecimientos

A mi papá Lucio y mi nonna Yolanda que ya no están.

A mí hermosa familia, Haydeé, Sabrina y Adriano que me han acompañado durante esta etapa.

A mis amigos por ser mis amigos.

A mis directores Martín Pedro Gómez y José Ruzzante por sus consejos, sabiduría, paciencia e invaluable ayuda para concretar este trabajo.

A Julio Migliori por su predisposición, pasión y aporte durante el trabajo experimental. Así como también a Luis Esteban Bifignano por la asistencia y gentileza mostradas.

Al grupo ICES-Ondas Elásticas: Mary, Isabel, Darío, Valeria, Hernán, Miriam Nicolás, Cinthya, Graciela, Dino, Carlos y Diego por los consejos, charlas y compañerismo mostrado.

A Edgardo Cabanillas por su ayuda con los trabajos de electroerosión e inmejorable buen humor.

A Jorge Magallanes por su valiosa colaboración y ayuda en la temática de redes neuronales.

A Adriana y Guillermo por su importante asistencia y cordialidad en las sesiones de MEB y en la preparación, pulido y toma de dureza sobre las muestras.

A todas las autoridades, profesores y personal administrativo del IT Sabato, CNEA y UNSAM por la atención, excelencia académica y la posibilidad que me brindaron para poder llevar adelante el presente trabajo.

A todos los que me estoy olvidando de agradecer en este momento.

Resumen

El presente trabajo de tesis es una continuación de trabajos anteriores los cuales buscan realizar un aporte a la temática referente al control y monitoreo de la condición de la herramienta en procesos de mecanizado. Mediante la aplicación de la técnica de Emisión Acústica (EA) y la medición de la Fuerza de Avance (FA) del proceso de taladrado y el respectivo análisis de las señales resultantes, se pretende inferir el estado de herramientas de corte con diferentes tipos de desgaste artificialmente inducidos. Estas condiciones pueden ser indirectamente monitoreadas debido a que la alteración de la geometría de la herramienta (producida por el desgaste) origina una variación de las señales medidas durante el corte por la modificación en la dinámica del proceso de taladrado.

El desarrollo se basó en la utilización de cinco condiciones de broca. La primera es la de referencia (broca nueva), con filos en óptimo estado de corte. Las cuatro restantes poseen diferentes tipos de deterioros producidos de manera controlada. Estas brocas taladraron de forma sucesiva probetas de metal (acero SAE 1040) a las cuales se le realizó un control micrográfico en varias secciones para controlar la homogeneidad del material. Durante el taladrado se registraron las señales de EA y FA obtenidas al llevar a cabo el orificio. Una vez adquirida la información digitalizada, se procedió a su análisis mediante métodos estadísticos, evaluando valores promedios, desviaciones estándares y varianzas. Los parámetros característicos de EA analizados fueron Amplitud (AMP), Potencia Media (PM), RMS, Frecuencia Media (FM) y Energía Absoluta (EABS). Para esta metodología, el análisis de la varianza respecto el valor medio de la variable considerada logro la mejor clasificación, especialmente para el caso de la PM, donde se obtuvo resultados similares a los conseguidos en trabajos anteriores. Posteriormente se estudió la correlación lineal entre las variables de EA y FA, donde no se encontró correlación entre las mismas

A continuación se utilizó el procedimiento de componentes principales como una metodología para clasificar los diferentes casos de estudio, no brindando un resultado satisfactorio, lo que posiblemente puede ser atribuido a la no linealidad del proceso estudiado. Finalmente se utilizó una red neuronal no supervisada, tipo Mapa Auto Organizado para clasificar la información de las diferentes condiciones de desgaste. Como resultado esta red brinda un mapa topográfico donde sitúa las clases diferenciadas en distintas regiones de un mapa bi-dimensional. La arquitectura de la red fue sucesivamente modificada durante el proceso de entrenamiento, variando la cantidad de neuronas, factores de corrección, épocas de procesamiento, etc., hasta conseguir que los valores de error en la clasificación resulten inferiores al 5 %. Luego se procedió a la etapa de simulación, donde se alimentó a la red con datos diferentes a los del entrenamiento, los cuales clasificó de manera satisfactoria. Las simulaciones se realizaron con lotes de datos de varias dimensiones para evaluar el comportamiento general de la misma, logrando una clasificación de las diferentes condiciones de broca en todos los casos.

Palabras Clave: Taladrado – Emisión Acústica – Red Kohonen – Análisis de Señales – Monitoreo en línea.

Abstract

This thesis is a continuation of previous works which seek to contribute to the on line tool monitoring knowledge in machining process. By the application of Acoustic Emission (AE) method and the measurement of Thrust Force (TF) in drilling process, and the corresponding signal analysis, the identification of different level of wear in drilling bits is intended. That bits condition could be indirectly recognized by the variation of the dynamic behavior of the cutting process produced by the changes in the tool geometry caused by wear.

The development of this work is based in the utilization of five drill bits with different wear. One of the bits was in optimal condition, with sharp edges, and the other four were worn in different ways. With those drill bits, steel specimens of SAE 1040 were drilled. Metallographic studies were performed to assess the homogeneity of the drilled samples. During the drilling process AE and TF signals were acquired and digitalized. The information was analyzed by statistical methods as mean value, standard deviation and variance. The selected AE features were Amplitude (AMP), Mean Power (MP), RMS, Mean Frequency (MF), and Absolute Energy (EABS). In this case, variance vs. mean value of AE features and TF showed good possibilities of condition classification, specially the MP. Also the linear correlation between the AE parameters and the TF was evaluated, showing a very low values between the PM and the TF.

With the aim to reach a better classification of the drill bits condition, principal component analysis was performed. This method not showed satisfactory results due to the possibility that the drilling were a nonlinear process. For that reason, the approach by the use of a neural network to analyze the data was considered. The network used is an unsupervised network, Self-Organized Map (SOM). As result, the network give a two dimensional topological map of the information distribution. The architecture was successively modified during the training stage, changing the number of neurons, weight correction, and number of epochs until the classification performed reaches less than five percent of error. Once the network was trained, the simulation stage was carried out, feeding the net with new data which was satisfactorily classified. The simulations were done with matrix data of different size, achieving classification of the different condition of wear of the drill bits.

Keyword: Drilling – Acoustic Emission – Kohonen network – Signal Analysis – Online Tool Monitoring.

Publicaciones y presentaciones en actas de congresos

Trabajos que forman parte de los experimentos y resultados de la presente tesis:

1. G. Ferrari, M. Gómez, “Correlación entre Emisión Acústica, avance y desgaste de la herramienta en procesos de taladrado”, Actas SAM/CONAMET 2013. 13 Congreso Internacional en ciencia y tecnología de metalurgia y materiales.
2. G. Ferrari, M. Gómez, “Comparación de señales de EA en procesos de taladrado con y sin efecto de cincelado”, Actas E-GLEA 8, Encuentro del Grupo Latinoamericano de Emisión Acústica (2013).
3. G. Ferrari, M. Gómez, J. Magallanes, J. Migliori, “Clasificación de la condición de brocas en taladrado a partir del análisis de la Emisión Acústica mediante Redes Neuronales” Actas SAM/CONAMET 2014. 14 Congreso Internacional en ciencia y tecnología de metalurgia y materiales.
4. G. Ferrari, M. Gómez “Correlation between Acoustic emission, thrust and tool wear in drilling”. Procedia Materials Science, aceptado para edición (2014).

Índice

Introducción General	1
Capítulo 1: Descripción del proceso de taladrado y modelos teóricos de corte	5
1.1 Aspectos generales del taladrado	7
1.1.1 El taladrado y descripción de los diferentes tipos de broca	7
1.1.2 Características del proceso de taladrado	10
1.1.3 Consideraciones especiales en taladrado	11
1.2 Aspectos del proceso de corte, teoría de Corte Ortogonal y Corte Oblicuo	12
1.2.1 Introducción al proceso y modelos de corte	12
1.2.2 Relación entre corte y material desprendido. Filo Recrecido	10
1.2.3 Modelo de corte Ortogonal bidimensional	14
1.2.4 Modelo de corte Oblicuo	20
1.3 Desgaste y vida de la herramienta	24
1.3.1 Mecanismos de desgaste	27
Capítulo 2: Teoría básica de Emisión Acústica	31
2.1 Definición de la EA como proceso físico	33
2.2 EA como método de ensayo no destructivo	33
2.3 Fuentes de EA	33
2.3.1 Dislocaciones como fuentes de EA-Deformación Plástica	34
2.3.2 EA por Maclado	35
2.3.3 EA por variación de los dominios magnéticos – EMA.	35
2.3.4 EA en los diferentes procesos de fractura	36
2.3.5 EA por procesos de fricción	38
2.3.6 Otras fuentes de EA	38
2.4 Sensores de EA	39
2.4.1 Sensores capacitivos	39
2.4.2 Sensores interferométricos	39
2.4.3 Sensores piezoeléctricos	40
2.4.4 Otros sensores	42
2.5 Instrumentación de la EA-Sistema de EA	42
2.5.1 Preamplificadores	43
2.5.2 Equipo de EA: Amplificador-Parametrizador-Digitalizador	43
2.5.3 Modo de adquisición paramétrico	44
2.5.4 Modo de adquisición de formas de onda	45

2.5.5	Modo de adquisición streaming	45
2.5.6	Parametrización de las señales de EA	45
2.6	Fuentes de ruido que pueden afectar la EA y tratamiento de los mismos	48
2.7	EA en el control y monitoreo del estado de la herramienta.	49
Capítulo 3: Fundamentos de Redes Neuronales		53
3.1	Introducción	55
3.2	Arquitectura y funcionamiento básico de una neurona	55
3.3	Acondicionamiento de los datos de entrada a la red	59
3.3.1	Escalado tipo Minimax	59
3.3.2	Escalado tipo Autoescalado	59
3.4	Descripción del proceso de entrenamiento y predicción	59
3.5	Descripción de reglas de aprendizaje y red elemental “Perceptrón”	60
3.6	Red neuronal tipo Mapas Auto Organizados- Kohonen	63
Capítulo 4: Metodología Experimental		69
4.1.	Preparación del experimento	71
4.1.1	Brocas de taladrado	71
4.1.2	Probetas Hexagonales de Acero	74
4.1.3	Dispositivo para medición de Fuerza de Avance y soporte de probeta	76
4.1.4	Máquina de taladrado	76
4.1.5	Sistema de EA	77
4.2	Descripción del ensayo	78
4.3	Metodología para el análisis de los datos	79
4.3.1	Selección de la información a analizar	80
4.3.2	Análisis de la distribución de la información	81
4.3.3	Análisis de correlación lineal	82
4.3.4	Análisis por cálculo de Valor medio, Varianza, Desvío estándar	82
4.3.5	Análisis por Componentes Principales	83
4.3.6	Análisis mediante Redes Neuronales	83
Capítulo 5: Resultados y discusión		91
5.1	Caracterización de las etapas de corte por medio de la fuerza de avance	93
5.2	Análisis de normalidad de las señales de EA y FA	93
5.3	Análisis de correlación lineal y determinación de los parámetros a utilizar	96
5.4	Calculo de valores medios de los parámetros de EA y FA	97
5.5	Análisis de la correlación entre FA y PM	101

5.6	Análisis de la varianza y valores medios de los parámetros de EA y FA	102
5.7	Análisis por Componentes Principales	104
5.8	Análisis por redes Neuronales tipo Mapa Auto Organizado	108
5.8.1	Resultados del entrenamiento	108
5.8.2	Resultados de la predicción	114

Capítulo 6: Conclusiones **121**

Bibliografía **127**

Futuras líneas de investigación propuestas **125**

Apéndices

Apéndice A1: Método Hsu-Nielsen.

Apéndice A2: Planos constructivos y de despiece de dispositivo de medición de FA.

Apéndice A3: Gráficos de FA respecto tiempo de ensayo para todas las condiciones de broca.

Apéndice A4: Detalle de cantidad de datos pertenecientes al periodo de taladrado con *AG* clasificados por ensayo mediante el parámetro *FA*.

Apéndice A5: Gráficos de distribución y comportamiento normal de los parámetros medidos para todas las condiciones de broca.

Apéndice A6: Matrices de correlación lineal para las cinco condiciones de broca respecto a todos los parámetros de EA y FA medidos.

Apéndice A7: Valores medios de los parámetros respecto su desvío estándar para cada condición de broca.

Apéndice A8: Valores medios de los parámetros respecto de sus varianzas para todas las condiciones de ensayo.

Apéndice A9: Detalle de las diferentes arquitectura y configuraciones de redes neuronales probadas.

Introducción General

Los procesos actuales de maquinado son cada vez a mayores velocidades, con altas exigencias en tolerancias geométricas como de terminación superficial. Estos motivos hacen muy necesario contar con sistemas de control y alerta que indique el estado de la herramienta antes, durante y después del proceso de maquinado. Adicionalmente estos sistemas deberían indicar como es la performance del proceso a medida que se desarrolla. Una de las metas de los métodos de monitoreo es la aplicación a tiempo real, de manera de poder tomar las acciones correctivas necesarias para evitar la producción de piezas defectuosas. De esta manera se logra la optimización de los tiempos y costos de producción.

Por esta razón se desarrollaron métodos directos e indirectos de medición de la condición de desgaste de la herramienta, los cuales pretenden determinar el estado que los filos de corte antes que posibles fallas afecten de manera apreciable las condiciones del maquinado de la pieza de producción.

Los métodos directos en general buscan modificaciones en la geometría (desgaste) del herramienta con respecto a su estado original, esto se realiza mediante procesos de visión artificial, ópticos de medición laser y observación visual del operario sobre la herramienta. La ventaja principal de este método es la muy buena correlación entre el estado geométrico de la herramienta con respecto al proceso de maquinado y terminación. La desventaja de estos métodos es que no permiten un monitoreo continuo o en línea del proceso de maquinado a medida que se desarrolla (o si lo permiten es de muy dificultosa implementación), esto se debe al íntimo contacto entre la herramienta y la pieza, dando como resultado que no se pueda controlar durante el proceso si la herramienta está sufriendo un deterioro progresivo.

Los métodos indirectos basados en la medición de variables auxiliares como Fuerzas de Avance (FA), torque, Emisión Acústica (EA), vibraciones y otros, buscan correlacionar las señales adquiridas durante el proceso con la eficiencia en el maquinado y con el nivel de desgaste de la herramienta. En general estos métodos son menos efectivos que los métodos directos debido a que se tiene que identificar una variable del proceso que fluctúe con el desgaste de la herramienta y a su vez establecer una relación entre ellos. La aplicación de estos métodos se han llevado a cabo en procesos de torneado donde la herramienta esta estática con respecto a la pieza, siendo mucho más complejo en procesos como el fresado y taladrado debido a la rotación de la herramienta inherente al proceso de maquinado.

Existe una amplia cantidad de publicaciones sobre la utilización de la EA para el monitoreo en línea del estado de la herramienta aplicada a procesos de torneado y en menor cantidad a fresado y taladrado los cuales a su vez analizan la información de varias maneras seleccionado diferentes parámetros y aplicando diversas técnicas de análisis de señales.

Se entiende a la Emisión Acústica como la propagación de las ondas elásticas a través del material, estas ondas son producidas por una fuente emisora sobre la cual debe aplicarse algún tipo de excitación o sollicitación para que se active y las frecuencias de emisión se encuentran por sobre el umbral de audición humana. La EA puede ser utilizada como una técnica que asociada a otros sistemas de análisis sea aplicada como método indirecto monitoreo procesos dinámicos. Dentro de este tipo de procesos se encuentra el deterioro sufrido por los filos de una broca de taladrado durante el proceso de perforado, ya que a medida que este proceso se desarrolla, diferentes efectos que trabajan en forma conjunta provocan el deterioro continuo del utillaje de trabajo. Este deterioro se manifiesta como la modificación de la geometría de la herramienta de corte lo que hace que varíe la dinámica del corte generalmente hacia un estado de menor eficiencia. Consecuentemente esta negativa modificación en la dinámica del proceso impacta directamente aumentando los tiempos de proceso y reproceso debido que provoca piezas fuera de tolerancia dimensional o directamente piezas que deben ser dadas de baja por no tener recuperó. Adicionalmente otro factor a tener en cuenta es el estado de terminación o acabado superficial de la pieza que también depende del estado de la herramienta y generalmente se presenta defectuoso si el estado de la misma lo es. Finalmente todos estos factores repercuten de manera negativa en los costos de producción, lo que hace que sea económicamente favorable realizar un control del estado de la herramienta.

En trabajos anteriores se ha relacionado la EA y la fuerza de torque durante el taladrado con brocas en diferentes estados de deterioro. El presente trabajo es una extensión de estos, siendo las variables que se analizaran en este caso la EA asociada a la Fuerza de Avance del proceso de taladrado con brocas que contienen diferentes tipos de defectos como cráteres en la cara de ataque, flanco, eliminación de filos principales y otros. El cambio de la condición del proceso de corte debido a la variación geométrica de la herramienta produce que la señal de EA y la FA resultantes del proceso sufra modificaciones. Estas variaciones son producto de la modificación de la condición de fricción sobre la cara y flanco de la herramienta, ampliación de la zona de deformación plástica durante el corte, variación del flujo y forma de la viruta resultante, etc. Esta modificación en las señales de EA conjuntamente con la de la FA es la que de poder ser diferenciada y asociada la condición de trabajo identificara de forma indirecta el estado de la herramienta. Con esto en mente, se realizaron taladrados en probetas de acero SAE 1040 con brocas que cuentan con cinco condiciones de filo diferentes similares condiciones de proceso. Estos ensayos fueron monitoreados mediante EA y medición de la FA para luego analizar las señales resultantes y correlacionarlas con el tipo de deterioro de la broca.

Ahora bien, el análisis de dichas señales comprende un campo de estudio que generalmente está muy lejos de ser parte de la utilización del sistema de EA aplicado al campo de NDT en aplicaciones industriales, pero es proceso indispensable para analizar la información desde el punto de vista de la investigación del taladrado y poder asociar un tipo característico de señal a una condición de broca. Por lo tanto cuando se hace referencia a un sistema de monitoreo en línea del estado de la herramienta, se hace referencia a un conjunto de partes que comprende la adquisición y registro de la EA y FA, conjuntamente con su procesamiento y análisis, siendo el último paso la devolución de un resultado que sea fácilmente interpretado por un operador. Los análisis que se le realizaron a las señales de EA y FA comprenden análisis de tipos estadísticos como estudio de normalidad y correlación lineal, cálculo de valores medios, desviaciones y varianzas. Posteriormente se aplicaron técnicas de análisis multivariable como componentes principales, para observar si la información puede ser clasificada de mejor manera. Finalmente ante la posibilidad de que nuestras señales (y por lo tanto el proceso) se comporte de manera no lineal se aplicó como herramienta de análisis una red neuronal tipo Kohonen la cual permite realizar un análisis multivariable no lineal de la información, y adicionalmente brinda una clasificación de los datos en un formato de mapa con distribución topológica que es simple de comprender y donde sencillamente se puede observar la clasificación del estado de la herramienta, posibilitando que una persona no experimentada en el tema pueda analizar el resultado. Esto se llevó a cabo realizando variados entrenamientos de la redes con diferentes arquitecturas hasta llegar a una configuración que posibilito clasificar las condiciones de broca con un aceptable porcentaje de error. Con esta red entrenada se procedió al proceso de predicción alimentando a la red con datos nuevos los cuales clasifico de manera satisfactoria un porcentaje de error inferior al 5 %.

El presente trabajo de tesis se diagramó en seis capítulos donde los tres primeros corresponden a información que detalla el estado del arte de la temática estudiada, esta información brinda las bases teóricas para comprender los procesos y procedimiento que son aplicados en el resto del trabajo. Los tres capítulos restantes detallan la forma procedimental de los ensayos, análisis y resultados de los ensayos así como las conclusiones finales.

En el *primer capítulo* se introducen conceptos básicos relacionados con los diferentes tipos de brocas, condiciones óptimas de uso y geometrías generales. Además se presentan las teorías de corte ortogonal y oblicuo aplicada al corte de metales y posteriormente se examinarán los temas de desgaste y vida de la herramienta.

En el *segundo capítulo* se detallan los fundamentos de la EA y las diferentes fuentes de ondas elásticas, además de la parametrización realizada de la señal y una descripción de los equipos utilizados para la aplicación de la técnica.

El *tercer capítulo* realiza una introducción a la temática de redes neuronales de manera de comprender su funcionamiento básico y los lineamientos generales de cálculo. Luego se profundizara el análisis sobre un

tipo particular de red denominada Mapa Auto Organizado (Self Organized Map), también llamada Kohonen.

En el *cuarto capítulo* se detallan las condiciones en que fueron desarrollados los experimentos lo que comprende la medición de la FA y la EA del proceso en las diferentes condiciones. También se aborda el tratamiento de la información recolectada y su análisis mediante la utilización de estadística, correlación lineal, análisis por componentes principales y redes neuronales.

En el *quinto capítulo* se exponen los resultados obtenidos para las variadas condiciones de broca utilizadas, los diferentes parámetros de EA considerados conjuntamente con la FA, y las técnicas de análisis utilizadas.

Finalmente en el *sexto capítulo* se detallan las conclusiones extraídas del presente trabajo de tesis.

Capítulo 1

DESCRIPCIÓN DEL TALADRADO, HERRAMENTAL Y MODELOS TEÓRICOS DE CORTE

En el presente capítulo se introducen conceptos básicos relacionados con los diferentes tipos de brocas, condiciones óptimas de uso y geometrías generales. También se describirán buenas prácticas del uso de este herramienta y se discutirán consideraciones generales del proceso de taladrado. Luego se abordarán las teorías básicas de corte ortogonal y oblicuo, las cuales pretenden dar una idea cualitativa de la mecánica involucrada en el proceso de mecanizado. Por último, se examinarán los temas de desgaste y vida de la herramienta, describiendo las zonas de mayores exigencias del herramienta, los defectos característicos que producen diferentes condiciones de uso y algunos de los mecanismos de desgaste involucrados en el deterioro de la herramienta.

1.1 Aspectos generales del taladrado

1.1.1. El taladrado y descripción general de las brocas.

El taladrado se define como “el procedimiento de arranque de viruta con movimiento de corte circular y en el cual la herramienta solo tiene movimiento de avance en la dirección del eje de giro” [Appold y otros (1985)]. Estos procedimientos de mecanizado comprenden además, el escariado y el avellanado (Fig. 1.1).




Fig. 1.1 Diferentes procesos de taladrado [Appold y otros (1985)].

Aunque en la actualidad existe una amplia variedad de brocas de diferentes materiales, tipos, recubrimientos y geometrías. Hay que seguir siendo reconocibles en la mayoría de estas. Dentro de las más utilizadas se encuentran las de geometría helicoidal, con ranuras de forma espiralada que permiten la salida de la viruta y la entrada del fluido de corte (refrigerante/lubricante) a la zona de corte (Fig. 1.2).




Fig. 1.2 Descripción general de una broca helicoidal [Appold y otros (1985)].

Los biseles guían la broca dentro del orificio y son delgados para reducir el rozamiento sobre las paredes del mismo. Luego los bordes de los biseles constituyen los *filos auxiliares*. Las superficies generadas a partir de la ranura espiral receptora de viruta y las superficies destalonadas constituyen los *filos principales*, los cuales afilados correctamente generan una línea recta. Para lograr esto, las superficies destalonadas se deben afilar en forma curvilínea. En la punta de la broca se forma el *filo transversal*,

como intersección de las dos superficies destalonadas, siendo la continuación del filo principal y produciendo un efecto de rascado/cinzelado a medida que taladra el material. Las deformaciones producidas por el filo transversal son importantes y complejas. Específicamente en el centro de la herramienta, la única velocidad actuante es la velocidad de avance en sentido axial. Esto produce un efecto cinzelado, y al alejarse del centro la deformación es mayor debido a la combinación de las velocidades de avance y rotación de este filo [Oxford y otros (1955)]. Este proceso absorbe aproximadamente dos tercios de la fuerza de avance, y puede reducirse variando el ángulo de punta, siendo mínimo para valores cercanos a 55° . En La fuerza de avance puede reducirse aún más por adelgazamiento de la punta, pero entonces se disminuye la resistencia al desgaste de la herramienta. Detalles específicos de la geometría de una broca se pueden observar en la Fig.1.3.




Fig. 1.3 Detalle de las diferentes partes (filos, superficies y ángulos) de la broca [Appold y otros (1985)].

Otra característica importante de la broca es el ángulo de ataque (γ) que coincide con el ángulo de acanaladura y disminuye hacia el núcleo de la broca. Estos se eligen grandes para trabajar en materiales blandos y lo más pequeño posible para materiales duros. A continuación se brinda una categorización de las brocas según su ángulo de ataque y el material a trabajar en base a ello. En la Fig. 1.4b se muestran fotografías de tres brocas con diferentes ángulos de ataque.

Brocas helicoidales tipo N, $\gamma = 16^\circ$ a 30° para materiales con desprendimiento normal de viruta, acero y fundición de acero con resistencia tensil de hasta 700 N/mm^2 , ($\sigma = 118$), aleaciones de Cu desde CuZn 40, Níquel, acero inoxidable, ($\sigma = 140^\circ$).

Brocas helicoidales tipo H, $\gamma = 10^\circ$ a 13° para materiales duros y frágiles, aleaciones de Cu desde CuZn40 ($\sigma = 118^\circ$), acero de alta resistencia ($\sigma = 140^\circ$), materiales prensados, roca ($\sigma = 80^\circ$).

Brocas helicoidales tipo W, $\gamma = 35^\circ$ a 40° para materiales blandos, Aluminio, Cobre ($\sigma = 140^\circ$), aleaciones de Cinc ($\sigma = 118$).

El **ángulo de punta** (σ) como se muestra en Fig. 1.3 está formado por los filos principales donde las magnitudes de los mismos dependen del material a trabajar y están fijados empíricamente en las normas DIN 1414.

Generalmente, para materiales con gran resistencia al arranque de viruta y poca conductividad térmica (plásticos) hay que elegir brocas con un ángulo menor que para los metales.

El **ángulo de despeje** (α) se forma por el destalonado de la broca, estando comprendido entre el filo principal y la superficie de la pieza. Si este ángulo es pequeño, el dorso de la herramienta (superficie libre) fricciona sobre la pieza aumentando el rozamiento, el esfuerzo de corte y la temperatura de la broca. En la Tabla 1.1 se comparan los diferentes afilados y los tipos de material apropiados para trabajar en base a la geometría utilizada y en la Fig. 1.4a se puede observar una fotografía de los mismos donde se muestran los tipos de afilados A, B, C, D y E.

Tabla. 1.1 Cinco afilados especiales según DIN 1412.

	Detalle del afilado	Material
A	<i>Filo transversal adelgazado.</i> Poca fuerza de avance, mejores condiciones de corte	Acero con resistencia tensil hasta 900 N/mm ²
B	<i>Idem A</i> pero con filo principal corregido	Acero de más de 900 N/mm ² , acero de muelles, acero al Mn, fundición dura, aleaciones de Mg.
C	<i>Afilado en cruz.</i> El filo transversal se transforma en dos fillos auxiliares	Acero hasta 900 N/mm ²
D	<i>Afilado de doble cono.</i> Los sensibles extremos de los fillos están rebajados	Fundición gris, fundición dura, fundición maleable.
E	<i>Punta central.</i> Buen centrado, no se forman rebabas al taladrar	Aleaciones de Al, cobre, cinc, estratificado de papel




Fig. 1.4 (a). Diferentes tipos de afilados de broca. (b) Ejemplo de tres brocas con ángulos de ataque (γ) diferentes [Appold y otros (1985)].

Existen otros tipos de brocas basadas en similares principios, como los avellanadores huecos o de cuatro fillos (sirven para avellanar orificios previamente taladrados o antes de ser escariados).

Se pueden hallar también brocas de un solo filo utilizadas para orificios profundos, trabajan sobre macizos y tienen dos fillos comprendidos dentro de un ángulo de 120°. Los tres biseles le dan a la broca un buen guiado a lo largo de toda su longitud y fluido de corte para refrigeración y lubricación es conducido a presión hasta la zona de corte a través de un canal en su interior (Fig. 1.5). Otra variante son las brocas huecas, que constan de un tubo hueco y un cabezal porta broca. En la parte frontal del cabezal van montadas dependiendo del diámetro, de 2 a 16 cuchillas. Para reducir la carga sobre las cuchillas, sus fillos son de diferente anchura de forma de que cada cuchilla solo arranque una parte del ancho total del corte. Luego mediante líquido refrigerante se lubrica, enfría y expulsan las virutas (Fig.1.5).




Fig. 1.5 Broca de un solo filo y broca hueca de cuchillas [Appold y otros (1985)]

1.1.2. Características del proceso de taladrado.

Durante el taladrado, la broca avanza rotando, en dirección de su eje longitudinal introduciendo los filos principales en el material y arrancando la viruta, luego esta viruta es conducida por los canales helicoidales al exterior del orificio. Se puede distinguir entre movimiento de corte (rotación) y movimiento de avance. La composición de ambos da un movimiento diagonal a estos que se denomina *movimiento efectivo* (Fig. 1.6).




Fig. 1.6 Movimiento de corte efectivo y detalle del corte [Appold y otros (1985)].

La velocidad de corte y el avance determinan el rendimiento de la broca. Como base de la economía del herramental y del proceso se requiere un alto rendimiento, que se traduce en un volumen de viruta arrancado de la pieza por minuto. La velocidad de corte V expresada en m/min es el trayecto en metros recorrido por el bisel del filo principal de la broca en un minuto. El avance se expresa en mm, y es la medida de la penetración de la broca en el material de la pieza en una revolución. Para una broca dada, un aumento en la velocidad de corte significa un aumento de la velocidad de giro n (RPM), y con ello un aumento en el volumen de material removido en un dado período de tiempo. Un incremento en la velocidad de corte y en la fuerza de avance supone un aumento del calentamiento y del desgaste del filo de la herramienta. La velocidad de corte más económica depende del material de la pieza, de la refrigeración y de la duración de la broca bajo condiciones de corte en caliente. En la Tabla 1.2 figuran las velocidades de giro y avances que deben ser utilizadas para el taladrado de diferentes materiales (estos valores cambian según el diámetro de broca utilizado).

Tabla 1.2. Velocidad de corte (V) y de avance (S) para brocas de acero rápido y distintos materiales [Appold y otros (1985)].

Material	Acero hasta St 60	Fundición Gris	Cobre	Metales Ligeros
V en m/min	30-40	12 -30	30-60	100-150
S en mm	0.1 -0.4	0.1-0.6	0.1-0.6	0.1-0.6

Para brocas de acero de herramientas, la velocidad de corte se reduce a la mitad de estos valores y para brocas con filo de metal duro aumentan de cuatro a cinco veces. Los avances permanecen aproximadamente iguales.

La velocidad de giro, el diámetro de la broca y la velocidad de corte están relacionados entre sí. El recorrido periférico del filo de la broca en una revolución es $S_1 = d \cdot \pi$, y en n revoluciones es:

$$S = d \cdot \pi \cdot n \quad \text{donde } n = n [1/\text{min}] \text{ y } d = d [m]$$

De esta manera la velocidad de corte de la broca se define como:

$$V = \frac{S}{T} = \frac{d \cdot \pi \cdot n}{1} \left[\frac{m}{min} \right]$$

El montaje de la broca sobre la máquina se realiza mediante un mandril con mordazas de sujeción sobre el husillo del taladro. Para brocas pequeñas se usa una mordaza de tres dientes, y cuando hay frecuentes cambios de broca, o cambios con la máquina en funcionamiento, las mordazas utilizadas son de *cambio rápido*. Las piezas a mecanizar deben estar firmemente sujetas para que no sean arrastradas por el giro de la broca. En el taladrado de orificios pasantes los filos principales se agarran al final del recorrido en el material, y se crean grandes esfuerzos giratorios que hacen que la pieza se desplace o eventualmente pueda ser expulsada del soporte.

1.1.3 Consideraciones especiales en taladrado

Una variada cantidad de motivos pueden ser causa de piezas o trabajos defectuosos, mal terminados y de rotura o desgaste anticipado de las herramientas de corte. Al comenzar a generar un orificio en el taladrado, al momento inicial de contacto entre la broca y una superficie plana del material, la punta no tiene guía. Esto produce un movimiento errático entre diferentes posiciones hasta encontrar una posición de equilibrio estable de trabajo, con la posibilidad que el orificio se efectúe fuera de la especificación de plano. Por esa razón en general se marca con un punzón el punto para el posicionamiento de la herramienta. Si el orificio a taladrar es grande, o se requiere precisión, entonces se realiza un agujero guía de dimensión similar al diámetro comprendido por el filo transversal de la broca que se pasará a posterior. De esta manera, se elimina la acción de cincelado del filo central y se centra la broca durante todo el recorrido.

Otro problema usual es el chirrido de la broca durante el proceso de taladrado. Esto se evidencia en una variedad de condiciones, por ejemplo biseles de guiado gastados, husillo con demasiado juego axial, elección incorrecta del tipo de broca, afilado incorrecto o defectuoso, etc.

Otra característica distintiva de una defectuosa condición de corte es el excesivo calentamiento de la broca, que puede deberse a una incorrecta elección de los parámetros de avance y velocidad de corte, filo defectuoso, mala refrigeración y lubricación. La refrigeración disminuye la temperatura de los filos de corte y la lubricación el rozamiento entre la broca y la pieza que se trabaja. Los *fluidos de corte* son emulsiones de refrigeración y lubricación, algunas solubles en agua. Estos se usan en el taladrado de acero, aluminio, aleaciones de Cu y Zn. Las aleaciones de Mg, fundiciones, caucho endurecido y plásticos se taladran sin lubricación.

1.2 Aspectos del proceso de corte, teoría de Corte Ortogonal y Corte Oblicuo

1.2.1 Introducción al proceso y modelos de corte

Durante el presente trabajo se estudiarán las variaciones de los procesos activos del corte tales como deformación plástica, fricción, arranque de viruta y otros, que son fuentes de ondas elásticas de EA. Lo que debe comprenderse es que al modificarse la condición dinámica del corte (variación de la deformación plástica, fricción viruta, etc.) debido a la variación de la condición de la herramienta (geometría), se modifican algunos parámetros característicos de estas fuentes de EA y por lo tanto la emisión producida. Para tener un mejor entendimiento los factores que las afectan, es necesario conocer cómo se desarrolla el proceso de corte.

A continuación se presentan modelos de cálculo de las componentes de fuerzas, tensiones y ángulos específicos de la herramienta sobre la pieza a mecanizar. Además se observará la formación y flujo de viruta en el momento del corte, los ángulos de salida, la forma de la viruta cortada y el espesor de la misma. Existen modelos que consideran comportamientos no lineales en la dinámica de corte, la literatura muestra diferentes análisis realizados mediante elementos finitos que abordan la problemática desde el punto de vista mecánico y térmico. Estos evalúan las relaciones entre tensiones y deformaciones, considerando comportamientos elásticos y plásticos. También tienen en cuenta las variaciones del flujo del material, mallado, etc. La precisión de estos modelos estará condicionada al tipo y calidad de la información con la que se los alimente y para esto es necesaria la experimentación, la observación y la generación de teorías de corte como las que serán las explicadas a continuación. Primeramente se analiza el caso simple de corte ortogonal donde el filo de la herramienta está posicionado de manera perpendicular respecto a la velocidad relativa entre la pieza y la herramienta Fig. 1.7. Luego este modelo será extrapolado al caso de corte oblicuo que es más similar a la situación de corte producida por la broca de taladrado.




Fig. 1.7 Detalle de posicionamiento del filo de la herramienta respecto a la velocidad de avance de la misma para obtener corte Ortogonal [modificado de ASM International (1989)].

1.2.2 Relación entre corte y material desprendido (viruta). Filo recrecido

Para poder realizar los análisis anteriormente mencionados se suelen realizar ensayos donde se trata de “congelar” el proceso de corte para poder medir y cuantificar diferentes variables y así poder alimentar de valores los modelos de cálculo [Child y otros (2000)]. Un ejemplo de estos ensayos se muestra en la Fig. 1.8 los cuales corresponden a micrografías realizadas durante el desprendimiento de la viruta en el momento del corte. Estas fueron tomadas mediante un ensayo de parada rápida en un proceso de torneado

con herramientas en óptimas condiciones. En la Fig. 1.8 a se observa que la viruta resultante tiene un flujo continuo, recto y prolijamente apilado, para el maquinado de latón 70/30 (de relativamente fácil maquinado). En la Fig. 1.8 b se muestra viruta continua, más segmentada y en forma de diente de serrucho, producida en un acero inoxidable. Otras condiciones de proceso (material, velocidad de corte, lubricación, ángulos de herramienta, etc.) hacen que la ductilidad de la viruta no sea la suficiente para generar un flujo continuo, formándose viruta discontinua como en el caso del latón fragilizado por la adición de plomo (Fig. 1.8 c) y del acero dulce maquinado a bajas velocidades (Fig. 1.8 d). En las dos últimas micrografías se muestra una variación de la zona anterior al corte por distorsión plástica (poca en un caso y mucha en el otro). En otros casos, de manera cíclica, una parte del material trabajado envuelve y se apila sobre el filo de la herramienta de corte modificando su geometría (filo recrecido). Esto varía las condiciones ideales de corte. En la Fig. 1.8 e se puede observar la condición de filo recrecido para un acero dulce a velocidad de corte intermedia. Aumentando la velocidad y temperatura durante el proceso de corte el filo recrecido se achica o no sobrevive y el flujo de viruta para el acero dulce (Fig.1.8 f) es muy similar al de la Fig. 1.8 a. En general, se analiza el flujo de viruta continuo producido con la herramienta afilada (filo agudo) y con la cara de ataque recta, ya que de variar el ángulo de ataque de la herramienta varía el ángulo de corte y por lo tanto tipo de viruta obtenida [Enahoro y otros (1965)]. De esta manera, se determinan las diferentes características geométricas del flujo y de la viruta (profundidad, ángulo de corte, etc.) que permiten determinar las fuerzas, tensiones y flujos involucrados en el proceso de corte.

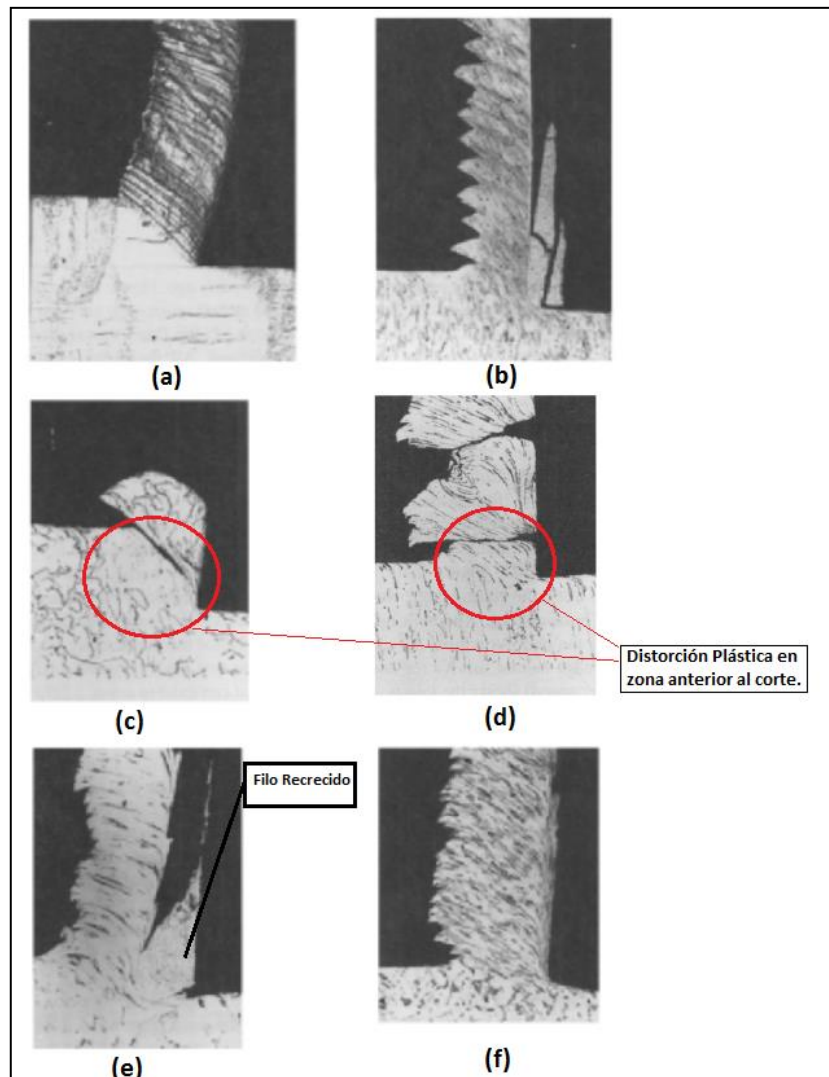


Fig. 1.8 Micrografías del proceso de corte en diferentes materiales [Modificado de Child y otros (2000)].

1.2.3 Modelo de Corte Ortogonal bidimensional

Hay varios modelos para describir el proceso de corte, algunos más precisos que otros. Estos modelos pueden explicar los fenómenos observados e indicar los cambios que conlleven hacia una mejora del proceso. Los modelos de corte más difundidos son el *de lámina delgada* o de “zona fina” utilizado por Piispanen (1948), Merchant (1945) y el modelo de “lámina gruesa” o “zona gruesa” utilizado por Oxley (1961) y otros. Estos modelos se esquematizan en la Fig.1.9 donde se aprecia la variación de la zona de afectada por el plano de corte durante el proceso de fractura del material en cada una de las situaciones y puede observarse claramente en las micrografías de la Fig. 1.8 a y 1.8 d.

Según datos experimentales el modelo de *lámina gruesa* podría describir mejor los procesos de corte a baja velocidad, mientras que modelo de *lámina delgada* lo haría mejor para procesos a velocidades mayores. En general, el modelo más utilizado es el de lámina delgada porque brinda mejores resultados y su tratamiento matemático es más simple. Este modelo es explicado a continuación.




Fig. 1.9. Los dos modelos básicos para el análisis de corte de metales. **a)** Lámina delgada, **b)** Lámina gruesa. [Armarego (1969)]

1.2.3.1 Análisis de Merchant (lámina delgada).

La hipótesis del modelo se basa en las siguientes condiciones:

- I. El extremo de la herramienta es agudo (bien afilado) y no existe arrastre o efecto de arado entre la herramienta y la pieza.
- II. La deformación en la zona de corte es bi-dimensional y no existe deformación lateral.
- III. Las tensiones en el filo de corte están uniformemente distribuidas.
- IV. La resultante de la fuerza R sobre la viruta aplicada en el plano de corte es igual, opuesta y colineal con la fuerza R aplicada por viruta a la interfaz herramienta-viruta.

En la Fig. 1.10 se muestra la construcción del diagrama de fuerzas involucradas. La resultante R puede ser relacionada con la fuerza de fricción F a lo largo de la superficie de la cara de ataque, o con la fuerza de avance (F_p) en la dirección del desplazamiento.




Fig. 1.10 Diagrama de fuerzas utilizado en el modelo de Merchant [Armarego (1969)].

Como la resultante R de las fuerzas sobre la herramienta puede cambiar en magnitud y dirección, es conveniente considerar las componentes de R, F_p y F_q de manera paralela y perpendicular a la velocidad de trabajo respectivamente. Estas fuerzas están determinadas por las siguientes ecuaciones:

$$F_p = \frac{t \cdot b \cdot \tau \cdot \cos(\beta - \alpha)}{\sin\phi \cdot \cos(\phi + \beta - \alpha)} \quad (Ec. 1)$$

$$F_q = \frac{t \cdot b \cdot \tau \cdot \sin(\beta - \alpha)}{\sin\phi \cdot \cos(\phi + \beta - \alpha)} \quad (Ec. 2)$$

τ = Tensión uniforme de corte sobre el plano de corte.

ϕ = Ángulo del plano de corte (Ver Fig.1.9 a).

α = Ángulo de ataque de la cara de la herramienta.

t = Espesor de viruta sin deformar.

b = Ancho del corte.

β = Angulo entre la resultante R y la normal a la cara de ataque. Este ángulo representa el ángulo de fricción entre la herramienta y la viruta extraída del material.

Con las Ec. 1 y Ec. 2 se pueden calcular las fuerzas de corte si se conoce la tensión de corte, el ángulo de fricción y el ángulo de corte. El resto de las variables quedan determinadas por las condiciones del proceso y por lo tanto sus magnitudes pueden ser conocidas.

El *ángulo de corte* (ϕ) es una característica propia del corte de un material. Este define la forma en que se va a deformar y el mismo puede ser evaluado analíticamente. Merchant (1945) considero que τ debería tener el valor límite dentro del material y que μ (coef. de rozamiento) debería tener un valor correspondiente al μ en condiciones de deslizamiento en seco. Para determinar ϕ se asumió el principio de “*mínima energía*” aplicado al corte de materiales de manera que el proceso de deformación converge a un nivel mínimo de energía. Para establecer esta condición planteo que:

$$\frac{dF_p}{d\phi} = 0$$

$$\frac{dF_p}{d\phi} = \frac{t \cdot b \cdot \tau (\beta - \alpha) \cdot \cos(2\phi + \beta - \alpha)}{\sin^2\phi \cdot \cos^2(\phi + \beta - \alpha)} = 0$$

De donde se obtiene una expresión para el ángulo de corte ϕ .

$$\phi = \frac{\pi}{4} - \frac{1}{2} \cdot (\beta - \alpha) \quad (Ec. 3)$$

Luego se reemplaza en (Ec. 1) y (Ec. 2) el valor de ϕ hallado con la condición de mínima energía (Ec. 3) y se obtiene:

$$F_p = 2 \cdot t \cdot b \cdot \tau \cdot \cot\phi \quad (Ec. 4)$$

$$F_q = t \cdot b \cdot \tau (\cot^2\phi - 1) \quad (Ec. 5)$$

Las Ec. 1 y Ec. 2 son válidas para el modelo de lámina delgada. Las Ec. 3, 4 y 5 están basadas en dos condiciones o planteos que pueden ser cuestionados. El primero es el que involucra el criterio de “*mínima energía*”, el cual no está soportado por ninguna evidencia de que así sea. Por otro, la suposición que β y τ son constantes en la diferenciación que los hace independientes de ϕ . Esta suposición no es completamente correcta existiendo argumentos que involucran fuerzas de fricción y tensiones de corte que relacionarían a β y a ϕ .

Merchant realizó experimentos para determinar las fuerzas de corte, ángulos de corte, coeficientes de fricción y tensión de corte del material, encontrando que los valores obtenidos diferían bastante con los valores teóricos calculados.

1.2.3.2 *Determinación del ángulo de corte.*

Existen distintos métodos para la determinación experimental del ángulo de corte. Uno es la observación directa de la deformación mediante un microscopio y la medición del ángulo con transportador o goniómetro. Para obtener estas muestras se pueden recurrir a técnicas de fotografía del corte o métodos de parada rápida que “congelan” la deformación de la viruta para su análisis. Otros métodos por ejemplo involucran la continuidad entre la viruta y la pieza maquinada que queda determinada al conocer la longitud del corte y aplicando el teorema de continuidad:

$$\rho lbt = \rho l_c b t_c$$

Donde l_c y t_c son la longitud y profundidad de la viruta y ρ es la densidad del material.

Algunas condiciones que se establecen en este planteo son que el material es incompresible y que no aparece propagación lateral del material. En base a esto se pueden plantear relaciones entre el espesor y la longitud de corte, y finalmente calcular el ángulo de corte.

Si no se conoce directamente la longitud del corte, se calcula en base al peso de la viruta extraída y de su longitud.

$$W = \rho l_c b t_c = \rho lbt$$

Siendo W el peso de la viruta.

Si se conocen la velocidad de la pieza y de la viruta, se puede determinar la relación de espesor del material antes y después del corte, en base a las velocidades de corte.

$$V\rho bt = V_c\rho b t_c$$

$$\frac{t}{t_c} = \frac{V_c}{V} = r$$

Siendo r, el coeficiente entre los espesores de viruta antes y después de cortar.

1.2.3.3 *Determinación del coeficiente de fricción*

El coeficiente de fricción (μ) de dos superficies deslizantes está definido como el cociente entre la fuerza en la dirección del deslizamiento (F) y una fuerza normal a F denominada (N) que actúan sobre la cara de ataque de la herramienta. Se puede plantear en base a la Fig. 1.10 las fuerzas actuantes:

$$\mu = \frac{F}{N} = \frac{F_p \sin \alpha + F_q \cos \alpha}{F_p \sin \alpha - F_q \cos \alpha} = \tan \beta$$

donde β es el ángulo de fricción.

Este concepto de fricción entre pares metálicos implica que tanto F como N sean consideradas como fuerzas uniformemente distribuidas. Esta consideración no es completamente correcta en el proceso de corte de metales.

1.2.3.4 Determinación de las tensiones, deformación, tasa de deformación y velocidad de corte.

De acuerdo al diagrama de la Fig. 1.10 b las fuerzas en el plano de corte están dadas por:

$$F_S = \text{Fuerza de corte} = F_p \cdot \cos\phi - F_q \cdot \sin\phi$$

$$F_N = \text{Fuerza normal} = F_p \cdot \sin\phi + F_q \cdot \cos\phi$$

Las tensiones de corte y las tensiones normales están dadas por las ecuaciones:

$$\tau = \text{tension de corte} = \frac{F_S}{A_S} = \frac{(F_p \cdot \cos\phi - F_q \cdot \sin\phi) \cdot \sin\phi}{b \cdot t} \quad (\text{Ec. 6})$$

$$\sigma = \text{tension normal} = \frac{(F_p \cdot \sin\phi + F_q \cdot \cos\phi) \cdot \sin\phi}{b \cdot t}$$

Donde A_S es el área del plano de corte determinado por: $b \cdot t / \sin\phi$.

De la composición gráfica de los vectores de velocidad en la Fig. 1.11 se puede calcular la velocidad de corte (V_s), siendo (V_c) la velocidad de la viruta.




Fig. 1.11 Relación entre ángulo de corte, espesor de viruta y velocidades de viruta [Armarego (1969)].

$$V_C = \frac{\sin\phi}{\cos(\phi - \alpha)} \cdot V = r \cdot V$$

$$V_S = \frac{\cos\phi}{\cos(\phi - \alpha)} \cdot V \quad (\text{Ec. 7})$$

Para obtener una expresión de la deformación de viruta durante el corte (γ) se puede idealizar el proceso de deformación como el deslizamiento de superficies o bloques por planos de deslizamientos preferenciales como se muestra en la Fig. 1.12 los cuales se apilan uno sobre el otro. Este mecanismo de corte y apilamiento puede ser claramente observado en la micrografía de la Fig. 1.8a.




Fig. 1.12 Superficie de deslizamiento en la que se apila la viruta extraída [Armarego (1969)].

Donde se plantea que la *deformación de corte* (γ) puede ser descrita de la siguiente manera:

$$\gamma = \frac{\Delta s}{\Delta y} = \frac{AB}{CD} = \frac{AD}{CD} + \frac{DB}{CD} = \frac{\cos\alpha}{\sin\phi \cdot \cos(\phi - \alpha)} \quad (\text{Ec. 8})$$

La deformación de corte también puede ser expresada en función de la velocidad de corte si consideramos Ec. 6 y Ec. 7:

$$\gamma = \frac{Vs}{V \cdot \sin\phi}$$

La tasa de deformación se expresa como:

$$\dot{\gamma} = \frac{\Delta S}{\Delta y \cdot \Delta t} = \frac{Vs}{\Delta y} = \frac{\cos\alpha}{\cos(\phi - \alpha)} \frac{V}{\Delta y}$$

Donde Δy es el espesor de la zona deformada y Δt es el tiempo necesario para llegar al valor final de la deformación.

Experimentos llevados a cabo por Merchant y otros investigadores han demostrado que el análisis cualitativo anterior describe en forma satisfactoria el proceso de corte. Cuantitativamente la relación del ángulo de corte (Ec. 3) se ha hallado inexacta, además los valores de las tensiones de corte y los coeficientes de fricción reales son mayores que los establecidos por ensayos convencionales de tensión y fricción.

1.2.3.5 Relación del ángulo de corte.

En el corte de metales, la relación del ángulo de corte es de particular importancia, ya que es una medida de la deformación plástica que ocurre durante este proceso. Además, es un parámetro relevante para predecir de manera analítica las fuerzas de corte. Por estas razones, existe una gran cantidad de trabajos al respecto de donde extraer las relaciones para el ángulo de corte y donde muchas de ellas pueden ser resumidas de la siguiente manera:

$$\phi = C_1 - C_2 \cdot (\beta - \alpha), \text{ donde } C_1 \text{ y } C_2 \text{ son constantes.}$$

La relación expuesta por Merchant para el ángulo de corte es posiblemente una de las más conocidas, además de ser una de las primeras formulada.

1.2.3.6 Procesos de fricción en el corte de metales.

El valor promedio del coeficiente de fricción entre la viruta y la cara de la herramienta puede ser calculado mediante la medición de las fuerzas de corte. Con este método se ha encontrado que dicho coeficiente es excepcionalmente alto y varía con la geometría de la herramienta entre otros factores. Esto no concuerda con lo que se espera en los procesos de fricción deslizante entre pares de metales, a los cuales se asimila para modelar el par viruta-herramienta. Para salvar estas diferencias se hará una breve explicación de los mecanismos generales de fricción deslizante en ambos casos.

En general, la superficie de los sólidos tiene irregularidades a nivel microscópico (Fig. 1.13), por lo que es de esperarse que cuando dos superficies se aparean, no habrá un contacto completo entre las “superficies aparentes o geométricas”.




Fig. 1.13 Representación de los puntos de contacto entre las dos superficies [Modificado de Armarego (1969)].

El área efectiva o real (A_r) es una fracción pequeña del área aparente A_a . El contacto se produce entre algunas de las irregularidades aisladas de las dos superficies y a medida que la carga aumenta, estos puntos de contacto aumentan acrecentando el área de contacto, primeramente con deformación elástica. Con un sensible aumento de carga, la deformación de las asperezas entra en período plástico y el área real de contacto es entonces una función directa de la carga aplicada, independiente del área aparente o geométrica de las superficies involucradas.

Se define entonces: $A_r = \frac{N}{p}$ donde N es la carga normal a la superficie y p es la tensión media de fluencia de las asperezas.

Cuando existen cargas normales y tangenciales actuando en las superficies, se desarrollan altas temperaturas en los puntos de contacto de las asperezas, lo que puede producir una unión (soldadura) entre las dos superficies. El movimiento tangencial entre las dos superficies debe involucrar el corte de las asperezas soldadas, este mecanismo en general se describe como teoría de *fricción adherente*, cuyo coeficiente de fricción es calculado como:

$$\mu = \frac{F}{N} = \frac{\tau \cdot A_r}{p \cdot A_r} = \frac{\tau}{p}$$

Donde F es la fuerza de fricción, N es la fuerza normal y τ es la tensión de corte de las asperezas soldadas.

Existe además otro mecanismo de fricción involucrado. Este implica la interferencia de las asperezas entre las dos superficies por lo que el deslizamiento se transforma entonces en arado (trabe y destrabe) de las asperezas de las dos superficies respectivas. Este último efecto puede sumarse al proceso de corte de las superficies soldadas, de manera que el coeficiente de fricción debido a estos dos fenómenos se describe como:

$$\mu = \frac{\tau}{p} + \frac{P}{N}$$

Donde P se define como la fuerza de arado. La importancia de los dos efectos, adhesión y trabado, dependerá de la naturaleza de las superficies en contacto.

1.2.3.7 *Fricción en la cara de ataque de la herramienta*

En el corte de metales se tiene una situación de deslizamiento con altas cargas normales y con una superficie de material químicamente limpia debido a que ha sido recién separada por el proceso de corte. La gran limpieza de la superficie del metal puede explicar los altos valores del coeficiente de fricción y además las altas cargas normales pueden justificar el porqué del apartamiento de este proceso del corriente comportamiento respecto de las leyes de la fricción entre pares metálicos. Además cuando se evalúa el coeficiente de fricción sobre la cara de ataque a través de las fuerzas de corte, se incluyen indirectamente la fricción de la pieza con respecto al flanco de despeje de la herramienta. Una de las formas para deducir esta componente de fricción es graficar las fuerzas de corte contra la profundidad de corte y extrapolar esto hasta llegar a una profundidad nula. El valor de la fuerza en ese punto se toma como la correspondiente a la fricción en el flanco y es restado del valor general.

La dependencia de μ con respecto a la condición de corte puede ser explicada considerando la distribución de tensiones en la cara de ataque de la herramienta. En la Fig. 1.14 se observa la distribución de tensiones donde en la longitud OA la tensión normal es muy alta y el material se adhiere a la cara de la herramienta sufriendo un flujo plástico. En esta región existen tensiones de corte que son independientes de la carga normal. Esta zona es llamada de *fricción adherente*. Luego de A hasta B existen menores tensiones normales y la condición corriente es *fricción deslizante*.

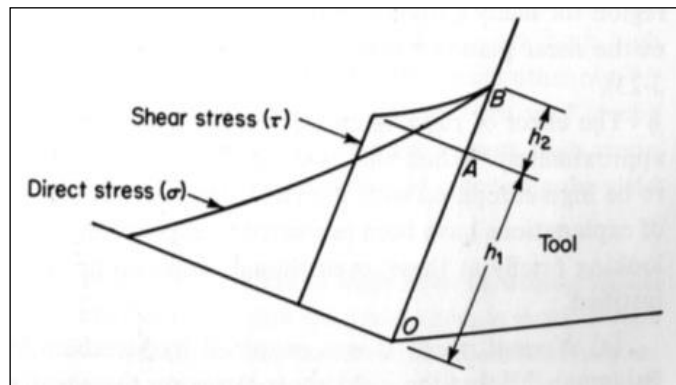


Fig. 1.14 Distribución de tensiones en el flanco de ataque [Armarego (1969)].

Entonces, μ en la zona de fricción adherente no es constante, pero depende de la magnitud de la carga normal y es menor que en la zona donde existe la condición de fricción deslizante. El valor medido del coeficiente de fricción es un promedio basado en las dos condiciones de fricción, por lo que es esperable que el mismo varíe con las diferentes condiciones de corte.

1.2.3.8. Tensiones de Corte

Las tensiones de corte calculadas en base a la Ec. 6 son más altas que las correspondientes al límite de fluencia del material considerado en un ensayo de tracción uniaxial. Una de las causas de este alto valor es el efecto de la fricción sobre el flanco de la herramienta que introduce fuerzas que son medidas pero que no participan en el proceso de corte. Otro factor influyente es la existencia de una región de *pre flujo* que extiende la longitud del plano de corte más allá de lo que es considerado por este análisis (Fig. 1.15) y puede ser observado en la realidad en las micrografías de la Fig. 1.8 c y 1.8 d.




Fig. 1.15 Detalle de región con “pre-flujo de material” [Armarego (1969)]

Los efectos de fricción y de la región de pre flujo pueden ser tenidos en cuenta de manera aproximada. A pesar de ello la tensión de corte seguirá siendo alta en comparación con el límite de fluencia del material cortado. A continuación se harán algunas consideraciones sobre el caso:

- I. *Tensión Normal*: Merchant (1945) y Bridgman (1937, 1943), sugirieron que el límite de las tensiones de corte en el plano de corte está acrecentado debido a los altos valores de las tensiones normales actuantes en ese plano.
- II. *Efecto Tamaño*: Shaw (2003) plantea que pequeñas zonas de deformación influyen en los valores de las tensiones de corte. Esto se basa en que en pequeñas zonas de deformación la probabilidad de encontrar fuentes de dislocaciones móviles (u otro tipo de defecto que disminuya la tensión) es reducida y por lo tanto el límite de fluencia aumentará. Experimentos muestran que a pequeña profundidad de corte los perfiles de las herramientas juegan un papel determinante en las fuerzas involucradas. La causa más probable del aparente aumento de las tensiones a pequeñas profundidades de corte sería debido al aumento de las fuerzas de fricción con respecto a al flanco de la herramienta.

- III. *Endurecimiento por Trabajado*: Algunos investigadores como Shaw (1950), Oxley (1961), afirman que el endurecimiento por trabajado juega un papel fundamental en las tensiones de corte del metal, mientras otros como Cottrell (1957), Kobayashi y Thomsen (1959) proponen que en este caso no sería relevante, excepto en procesos de corte a muy bajas velocidades.
- IV. *Velocidad de Deformación y Temperatura*: La velocidad de deformación y la temperatura normalmente se consideran que tienen influencia opuesta con respecto al límite de fluencia del material y debido a que tanto la temperatura como la velocidad de deformación son altas en el corte, suele considerarse que sus efectos se cancelan mutuamente [Shaw (1955)]. Sin embargo ensayos a muy altas velocidades de deformación, estas rápidas deformaciones pueden aumentar el límite de fluencia por encima del establecido en un ensayo estático.

1.2.4 Modelo de Corte Oblicuo

En la práctica son pocos los procesos de corte ortogonal puro. En general, muchos casos de corte son oblicuos, es decir que filos de corte de la herramienta son inclinados con respecto a la velocidad relativa entre la pieza y la herramienta. Esto obliga a extender el análisis del corte más allá del caso ortogonal a una condición más realista desde el punto de vista de uso industrial. A continuación se presentan consideraciones generales para la aplicación del corte oblicuo siendo un modelo que complementa el análisis de corte en el taladrado.

1.2.4.1. Geometría del corte con un solo filo

La mecánica del corte ortogonal indica que el ángulo de la cara de ataque es una variable fundamental para gobernar el ángulo y las fuerzas de corte. Uno de los problemas que surge del corte oblicuo es la selección de un ángulo de ataque que se corresponda con corte ortogonal. De esta manera el ángulo de ataque puede ser medido desde la cara de ataque hasta una línea perpendicular al vector de velocidad de corte. Sin embargo existen varios planos que cumplen con estas características, de los cuales se analizarán los tres más importantes. (Fig. 1.16)

- I. Plano normal al borde de corte (plano ABC). En este plano, el ángulo de ataque es llamado *ángulo de ataque normal* (α_n)
- II. Plano paralelo al vector de velocidad de corte y perpendicular a la superficie maquinada. (plano ABD) y se simboliza (α_v).
- III. Plano que contiene al vector de velocidad de corte y al vector correspondiente al flujo de la viruta (*ángulo efectivo de ataque*, plano AEF).

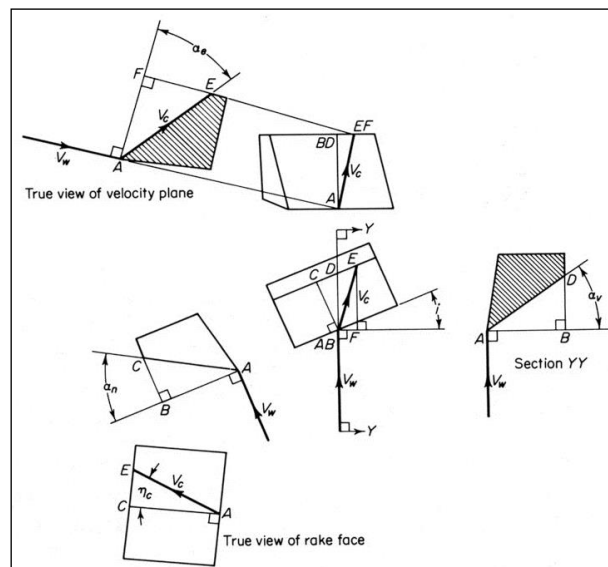


Fig. 1.16 Ángulos de ataque y velocidades en corte oblicuo [Armarego (1969)].

Estos tres ángulos pueden ser relacionados geoméricamente entre sí. El plano III que contiene al vector de velocidad de corte podría ser considerado uno de los más significantes por estar relacionado con los procesos de deformación, pero la fuerza de corte no es una función simple de este ángulo. La fuerza que actúa en la dirección de la velocidad de corte es función directa del ángulo I, entonces analizando desde el criterio de consumo de potencia, el *ángulo de ataque normal* es considerado como la correspondiente equivalencia al *ángulo de ataque* en corte ortogonal.

1.2.4.2. *Angulo de corte*

El plano de corte puede ser considerado como un plano que se extiende desde el borde de corte de la herramienta hasta la superficie de trabajo. También varias alternativas cumplen con esta consideración. Un ángulo de corte posible puede ser el que se encuentra en un plano normal al filo de corte de la herramienta, medido desde el plano de corte hasta la superficie de trabajo recién formada. Este ángulo es llamado *ángulo normal de corte*, (Fig. 1.17). Una definición alternativa es el *ángulo efectivo de corte*, este se corresponde con el *ángulo efectivo de ataque* y es medido desde el plano de corte, donde yace el vector de velocidad V_s , hasta la velocidad V_w .




Fig. 1.17 Ángulos de corte [Armarego (1969)]

1.2.4.3. *Relaciones entre velocidades*

Existen solamente tres componentes de velocidad en el modelo de lámina delgada, *velocidad de aproximación* (V_w), *velocidad de corte* (V_s) en el plano de corte y *velocidad de la viruta* (V_c) en el plano de la cara de la herramienta. Estas tres velocidades deben yacer en un plano y pueden ser relacionadas unas con otras. Al igual que en corte ortogonal estas relaciones pueden ser calculadas:

$$\frac{V_C}{V_W} = \frac{\text{sen}\phi_e}{\text{cos}(\phi_e - \alpha_e)}$$

$$\frac{V_S}{V_W} = \frac{\text{cos}\phi_e}{\text{cos}(\phi_e - \alpha_e)}$$

Una expresión más útil de estas ecuaciones puede ser hallada ya que las velocidades de corte y de viruta se pueden calcular en términos del *ángulo normal de corte* y del *ángulo normal de ataque*. Resolviendo las tres velocidades en un plano correspondiente a la nueva superficie de trabajo creada y en dirección normal al filo de corte:

$$\frac{V_c}{V_w} = \frac{\text{sen} \phi_n \cos i}{\cos(\phi_n - \alpha_n) \cos \eta_c}$$

$$\frac{V_s}{V_w} = \frac{\cos i \cos \alpha_n}{\cos \eta \cdot \cos(\phi_n - \alpha_n)}$$

1.2.4.4. Relación de fuerzas y tensiones.

En corte oblicuo la resultante de la fuerza R no se encuentra en un plano perpendicular a la superficie terminada como en el modelo de corte ortogonal y tampoco necesariamente al plano correspondiente a las velocidades. Es conveniente considerar las tres componentes de fuerzas en sentidos diferentes, una paralela al vector V_w de velocidad, otra perpendicular a la superficie terminada y una tercera perpendicular a estas dos. Estas son F_p , F_q y F_r respectivamente (Fig. 1.18).

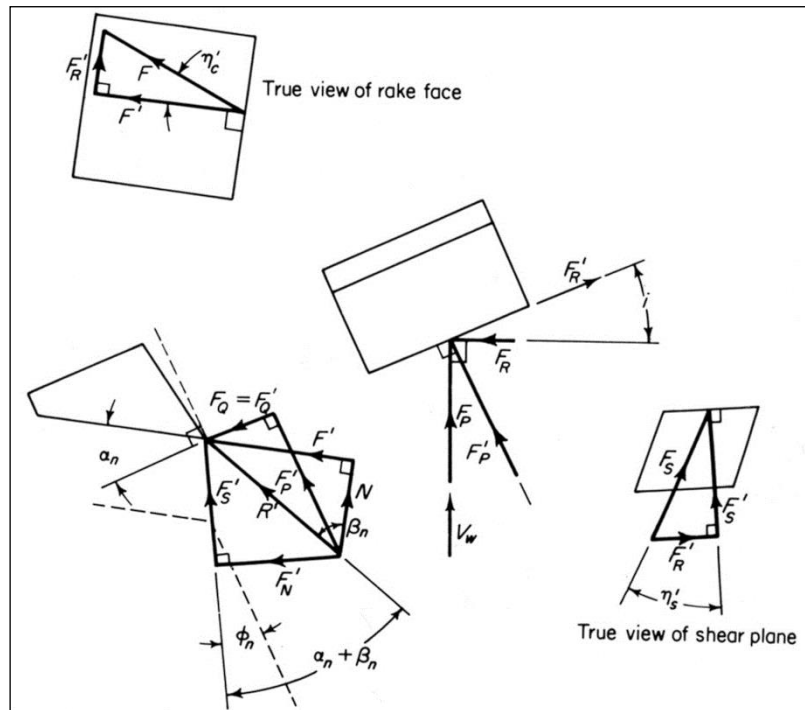


Fig. 1.18 Componentes de fuerzas en corte oblicuo [Armarego (1969)].

Para derivar las relaciones entre estas tres fuerzas en término de las tensiones en el plano de corte se formulan las siguientes hipótesis:

- I. La punta de la herramienta debe ser afilada y no deben actuar sobre ella fuerzas de rozamiento o arado.
- II. La distribución de tensiones debe ser uniforme en el plano de corte.
- III. La resultante de la fuerza R que actúa sobre la viruta en el plano de corte debe ser igual, opuesta y colineal a la fuerza actuante sobre la viruta que se encuentra en el flanco de la herramienta.

La resultante de la fuerza (R) puede ser descompuesta en dos componentes en el plano de corte, F_s y F_N , y dos componentes en la cara de ataque F y N . La fuerza de corte F_s se encuentra inclinada un ángulo η'_s con respecto a la normal del filo de corte y sobre el plano de corte. De manera similar la fuerza de fricción F se encuentra en un ángulo η'_c que es normal al filo de la cara de ataque. A su vez la resultante (R) puede ser resuelta en dos componentes, una R' que se encuentra sobre un plano perpendicular al filo de corte y otra F'_R a lo largo del filo de corte (Fig. 1.18). Luego R' se puede resolver igual que en corte ortogonal.

Los resultados analíticos de las componentes de las fuerza se pueden ver en las siguientes ecuaciones, las cuales no desarrollaremos aquí pero pueden ser consultadas en la bibliografía correspondiente [Armarego (1969)]. Estas ecuaciones son el análogo a las Ec. 4 y Ec. 5 desarrolladas para corte ortogonal.

$$F_p = \frac{\tau bt}{\text{sen}\phi_n} \cdot \frac{\cos(\beta_n - \alpha_n) + \tan i \tan \eta_c \text{sen} \beta_n}{\sqrt{\cos^2(\phi_n + \beta_n - \alpha_n) + \tan^2 \eta'_c \text{sen}^2 \beta_n}} \quad (\text{Ec. 9})$$

$$F_q = \frac{\tau bt}{\text{sen}\phi_n \cos i} \cdot \frac{\text{sen}(\beta_n - \alpha_n)}{\sqrt{\cos^2(\phi_n + \beta_n - \alpha_n) + \tan^2 \eta'_c \text{sen}^2 \beta_n}} \quad (\text{Ec. 10})$$

$$F_R = \frac{\tau bt}{\text{sen}\phi_n} \cdot \frac{\cos(\beta_n - \alpha_n) \beta_n}{\sqrt{\cos^2(\phi_n + \beta_n - \alpha_n) + \tan^2 \eta'_c \text{sen}^2 \beta_n}} \quad (\text{Ec. 11})$$

En base a las Ec. 9, 10 y 11 las componentes de fuerzas pueden ser calculadas si son conocidos el ángulo de corte (ϕ_n), el ángulo de fricción (β), la tensión de corte y la dirección de la fuerza de fricción η'_c .

Se han asumido como aproximaciones que la velocidad de la viruta y la fuerza de fricción son colineales y que la velocidad de corte y la fuerza de corte en el plano de corte son coincidentes. Considerando η_c igual a η'_c se demuestra que:

$$\tan(\phi_n + \beta_n) = \frac{\tan i \cdot \cos \alpha_n}{\tan \eta_c - \text{sen} \alpha_n \tan i}$$

Lo que finalmente permite establecer ϕ_n , determinando η_c y β o β_n .

La determinación de ϕ_n puede ser por los mismos métodos que en el corte ortogonal.

El corte oblicuo representa un modelo más complejo que el ortogonal y aun así no es completamente representativo del proceso de corte por taladrado, aunque provee una idea cualitativa de los eventos que suceden en el proceso de corte. Hasta aquí se ha descrito la herramienta de taladrado, dando nociones de su uso y las variedades existentes, también se describieron los modelos del proceso de corte y las ecuaciones correspondientes a las fuerzas, tensiones y ángulos de trabajo involucrados. A continuación se considerarán los fenómenos que limitan la vida de las herramientas y los defectos que producen.

1.3 Desgaste y vida de la herramienta

El desgaste de las herramientas es provocado por las altas cargas en la superficie de la misma, y tanto la viruta como la pieza que aplican estas cargas se mueven rápidamente respecto la herramienta. El corte y la fricción sobre estas superficies de contacto aumentan la temperatura del material y de la herramienta lo que acelera los procesos químicos y físicos asociados al desgaste.

El desgaste de la herramienta puede ocurrir a lo largo del filo de corte y en las superficies adyacentes. En la Fig. 1.19 a se muestra una vista del proceso de corte donde el borde de corte está definido por la intersección de la cara de ataque con el flanco de despeje. En la Fig. 1.19 b se pueden observar las zonas afectadas por desgastes típicos y la subsecuente modificación de la geometría de la herramienta.

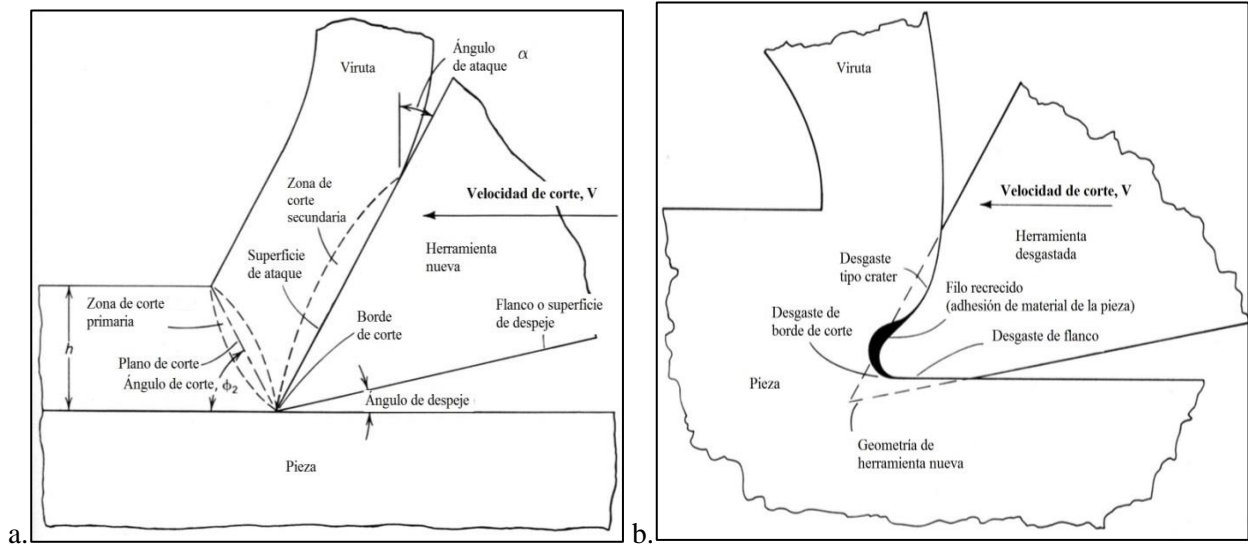


Fig. 1.19 a. Detalle del proceso con herramienta en condiciones de óptimo filo. **b.** Típicas superficies de desgaste. [Modificado de ASM Internacional (1996)].

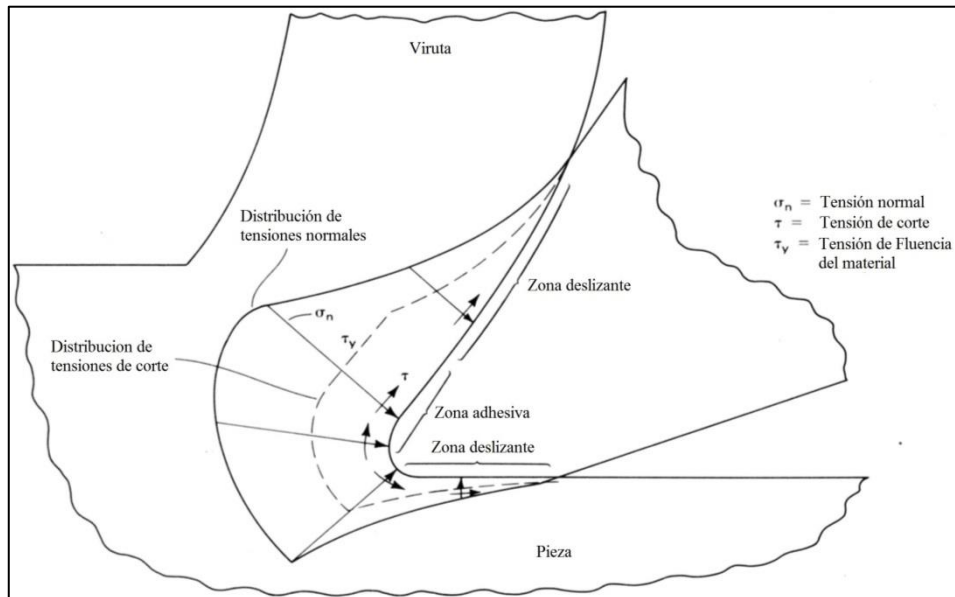


Fig. 1.20 Distribución aproximada de tensiones en cara de ataque [Modificado de ASM Internacional (1996)].

Las tensiones normales σ_n son causadas por fuerzas normales actuantes a lo largo de la superficie de ataque, borde de corte y flanco. Las tensiones de corte τ se producen sobre las superficies friccionantes y están asociadas a los mecanismos de fricción adhesiva y deslizante anteriormente descritos. Los resultados del desgaste se pueden catalogar básicamente en desgaste tipo cráter, filo recreado, desgaste del borde de corte y desgaste del flanco de despeje o incidencia. Los mismos están representados para diferentes herramientas en la Fig. 1.21. A lo largo de la cara de ataque el movimiento de la viruta y las altas tensiones normales producen un tipo de defecto llamado *desgaste tipo cráter* o craterización de la superficie. Sobre la superficie del flanco, el movimiento de la herramienta y las altas cargas normales incrementan el área de contacto entre la herramienta y la superficie de trabajo, produciendo lo que se denomina *desgaste del flanco*. Conjuntamente también se produce el efecto del aumento del radio del filo de corte.




Fig. 1.21 Superficies de desgaste en diferentes herramientas [ASM International (1996)].

Estos procesos cambian la geometría de las herramientas. El desgaste de los flancos, por ejemplo disminuye el diámetro en el caso de las fresas y varía la profundidad del corte en el caso del torneado. Estas variaciones pueden producir piezas fuera de tolerancia dimensional en las partes maquinadas. El desgaste del borde de corte y la craterización en la cara de ataque varían el estado tensional de la región de corte, cambiando consecuentemente las fuerzas de corte y el proceso de formación de la viruta. Una variación grande de la geometría entre la cara de ataque y el flanco puede debilitar la zona lo suficiente como para que el filo de la herramienta sufra una fractura repentina. La locación y el tamaño de las zonas de desgaste juegan un papel importante para determinar la vida útil de la herramienta ya que las tensiones altamente localizadas son el factor que más contribuye en la reducción de la vida de la herramienta.

La temperatura es otro factor que favorece el desgaste debido a que varía la condición de trabajo de la herramienta. Una variación en la velocidad de corte (velocidad relativa entre el flanco y la pieza trabajada) y en la velocidad de la viruta (velocidad relativa entre la viruta y la cara de ataque) conjuntamente con las tensiones de corte relacionadas en estas interfaces, determinan la cantidad de energía térmica liberada por unidad de área de contacto. Una alta velocidad de corte causa una alta tasa de deformación en la zona primaria de corte y este volumen de material deformado libera una cantidad adicional de energía térmica. Esta energía térmica es la fuente de calor que produce un aumento de temperatura en la pieza, la herramienta y el material removido. La relación entre la tasa de energía térmica generada y la disipada determina la temperatura del material en las zonas de desgaste. La energía disipada está en función de las propiedades conductivas del material, la herramienta. Adicionalmente el tamaño de la pieza y el calor específico determinan la capacidad de calentamiento de la misma. El desarrollo y la selección de materiales están basados en la habilidad de la herramienta de mantener su dureza, tenacidad y estabilidad química a altas temperaturas. En la Fig. 1.22 se muestra cómo varía la tensión de fluencia de diferentes materiales para herramientas de corte en función de la temperatura y con diferentes composiciones. Allí se puede observar que el continuo descenso de la tensión soportada por el material de la herramienta a medida que se incrementa la temperatura durante el proceso de corte.




Fig. 1.22 a. Tensión de fluencia de diferentes materiales de herramientas de corte en función de la temperatura. **b.** Distribución de temperaturas sobre la herramienta. [ASM Internacional (1996)].

La temperatura promedio de la herramienta en condiciones normales (filo en correcto estado, avance y velocidad de corte acordes entre otros) se calcula mediante la fórmula:

$$T = u \left(\frac{V \cdot h}{K \rho c} \right)^{\frac{1}{2}}$$

donde T es temperatura de la interface viruta-herramienta y u es la energía específica de corte.

La *energía específica de corte* se define como la energía necesaria para remover una unidad de volumen de material, V es la velocidad de corte y h es el espesor de viruta no deformado, luego k , ρ y c son conductividad, densidad y calor específico del material respectivamente. En la Fig. 1.22 b se aprecia la distribución esquemática de temperaturas, donde el alto gradiente de variación puede causar que partes de la herramienta lleguen a temperatura peligrosamente altas, muy por encima del valor medio, esto se da aproximadamente sobre la zona de fricción adherente y deslizante. Materiales altamente tenaces tienen altos valores de energía específica de corte, algunos como el titanio, también son pobres conductores del calor y de baja densidad. Esta combinación da como resultado una condición de alta temperatura en el corte, imponiendo mayores requerimientos a la herramienta.

1.3.1 Mecanismos de desgaste

Varios estudios han sido llevados a cabo para determinar los diferentes mecanismos de desgaste en herramientas de corte. Cualquier mecanismo en particular es dependiente del área de contacto, las velocidades relativas de las superficies de desgaste, temperatura y propiedades físicas de los materiales en contacto. Para un par específico de materiales en contacto se utilizan mapas que indican los rangos normales de presión y velocidad que determinan los mecanismos predominantes de desgaste. La Fig. 1.23 muestra un mapa general donde el área de contacto de la herramienta permanece constante, la temperatura no aparece, pero la misma está relacionada a la tensión normal (presión), velocidad y tamaño de la zona de desgaste. Los mecanismos generales que aparecen en el grafico son:

- Ataque o arranque de material.
- Desgaste por ablandamiento.
- Oxidación/Desgaste dominado por difusión.
- Desgaste dominado por plasticidad.

El área demarcada con línea de trazos determina una posible zona en la cual la herramienta trabaja en condiciones de seguridad. Existen además mapas similares para donde las variables son el avance de la herramienta el cual está relacionado con la presión para una condición y velocidad dada.

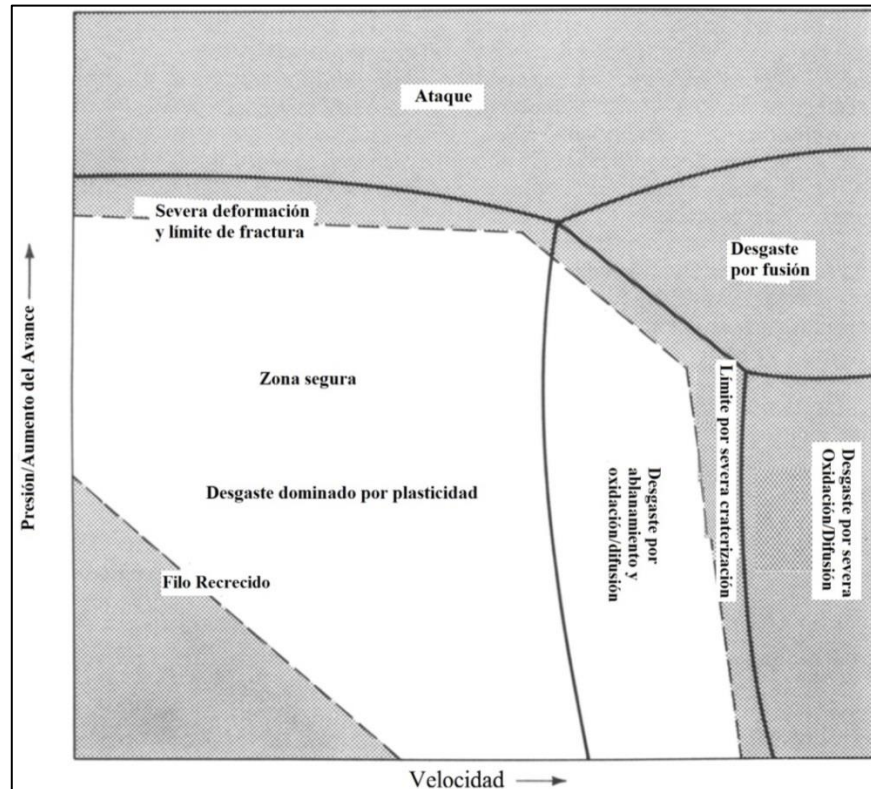


Fig. 1.23 Mapa de mecanismos de desgaste y zona de operación segura para herramientas de corte [Modificado de ASM International (1996)].

1.3.1.1 *Mecanismos de desgaste primarios*

Como se comentó con anterioridad los materiales tienen rugosidades e irregularidades que se ponen en contacto y esta área es proporcional hasta cierto límite a la fuerza normal aplicada. Las tensiones y la temperatura se concentran en las irregularidades y producen un arrancamiento parcial de las mismas, acompañado de fractura y derretimiento. A medida que estas asperezas son removidas, la tensión disminuye debido al aumento del área de contacto. Si las fuerzas permanecen constantes entonces la disminución de tensión provoca un cambio en los mecanismos de desgaste que cambian a deformación plástica, oxidación, difusión. Este período inicial de desgaste crea pequeñas pero visibles superficies de desgaste.

1.3.1.2 *Mecanismos estables de desgaste o secundarios*

La condición de desgaste primario debe tener una duración lo más corta posible ya que causa rápidamente la completa falla de la herramienta de corte. Asumiendo que dicha condición no exista, las superficies de desgaste progresivamente aumentan su tamaño. Si sobre estas superficies dominan los mecanismos de desgaste por deformación plástica, pequeñas partículas de material son mecánicamente deformadas, fracturadas y expulsadas fuera del área de desgaste. Esto se denomina abrasión y es el proceso más común a lo largo del flanco de despeje.

Las tensiones normales y la temperatura varían en las diferentes superficies de desgaste por lo que los mecanismos plásticos que pueden dominar en una región pueden no hacerlo en otra. La máxima temperatura de la herramienta ocurre en la cara de ataque a una pequeña distancia del borde de corte. Aquí es donde se produce el desgaste por craterización combinado con desgaste por difusión. La condición de alta temperatura y presión causa que los átomos se muevan entre las zonas de contacto y este proceso de difusión localizada ayuda a la remoción de material del cráter hacia la viruta de la pieza cortada. En algunas herramientas de carburo o cerámicas donde las velocidades de corte normalmente son muy altas, la oxidación y la difusión son los mecanismos predominantes y responsables del desgaste.

El desgaste puede también ocurrir en condiciones de filo recrecido si este eventualmente se fractura y vuelve a regenerarse o cuando se tiene una producción discontinua de viruta lo que resulta en un ciclo de impacto tanto térmico como mecánico sobre el borde de corte. Estos ciclos pueden provocar microfisuras que luego se propagan a lo largo del filo.

La abrasión, oxidación, difusión y formación de viruta discontinua son mecanismos de desgaste que aparecen en condiciones de operación en la zona segura y causan el desgaste de la herramienta a lo largo del tiempo pero de manera gradual por lo que se llama a este, *período estable de desgaste de la herramienta*.

1.3.1.3 *Mecanismos terciarios de desgaste*

El estado estable de desgaste eventualmente agranda las zonas de desgaste a un tamaño crítico que activa un desgaste acelerado. En herramientas que tienen recubrimientos resistentes al desgaste, como nitruro de titanio, sucede que progresivamente se remueve el recubrimiento y queda expuesto el material del interior de la herramienta el cual es menos resistente, resultando en un desgaste acelerado. Las presiones y velocidades en estas superficies hacen que la temperatura aumente y de manera rápida se produzca oxidación/difusión y arrancamiento localizado de material con ablandamiento, causando una rápida destrucción de la herramienta. Estos mismos procesos se dan en materiales con recubrimientos más blandos o en herramental sin recubrimientos. En cualquiera de los casos, el herramental debe ser cambiado antes de llegar a esta etapa.

Capítulo 2

INTRODUCCIÓN A LA TEORÍA DE EMISIÓN ACÚSTICA.

En este capítulo se realizará una breve introducción a los fundamentos de la Emisión Acústica como Ensayo No Destructivo (END) y como técnica para la caracterización de procesos. Además se detallan las diferentes fuentes de ondas elásticas en metales, los parámetros característicos de las señales y la forma de procesar la información. También se realiza una descripción de la instrumentación y equipos necesarios para llevar adelante la aplicación de esta técnica.

2.1 Definición de Emisión Acústica como proceso físico

Se entiende por Emisión Acústica (EA) a la energía elástica liberada de un material de manera espontánea cuando se ejercen ciertas acciones sobre él, como deformaciones o sollicitaciones mecánicas [Miller y otros (2005)]. Ejemplos de este fenómeno son las ondas elásticas que se generan en el interior de un material debido al avance de una fisura, y que se propagan por todo el cuerpo hasta su superficie. Durante el maclado del estaño, o cuando se procede a la curación de alguna vasija de barro o cerámica, estas ondas elásticas se encuentran en el espectro audible y pueden ser detectadas por el oído humano. Sin embargo estos casos son los menos frecuentes, ya que en casos de interés como el estudio de los materiales, el espectro de frecuencia de estas ondas elásticas está situado por encima del audible pudiendo llegar hasta los MHz, haciendo que sea imposible escucharlas por nuestro oído. Por lo tanto, a estas frecuencias es necesario contar con un dispositivo que permita captar, procesar y almacenar la información de estas ondas elásticas. De manera más general la EA puede generarse por cualquier mecanismo que convierta alguna forma de energía en energía elástica que se propagará por el medio, por lo tanto la energía transformada por la fuente puede ser de origen mecánico, electromagnético, químico, térmica etc. Esta liberación de energía ocurre de manera estocástica [Grabec (1980)] en un proceso que se denomina *evento de EA*. Estas fuentes de ondas elásticas van desde dislocaciones y avalanchas de dislocaciones en escala microscópica hasta eventos sísmicos a nivel macroscópico [Pollock (1973)]. En los materiales metálicos existen fuentes emisoras de varios tipos, algunas llamadas reversibles como las transformaciones de fase, fusión, solidificación, movimiento de dominios magnéticos o ferroeléctricos, y otras fuentes no reversibles que son las deformaciones plásticas, crecimiento de fisuras, avalanchas de dislocaciones, fractura de inclusiones y precipitados, corrosión, etc. Estos procesos por lo general involucran una degradación del material.

En no metales se puede detectar EA en procesos como roturas de fibras en madera, fracturas de piedras, rotura y fractura de fibras y matriz en materiales compuestos y otros muchos. Si tenemos en cuenta además que también procesos como soldadura, forjado, maquinado, pérdida en válvulas y tuberías, flujo de partículas, cavitación y otros fenómenos producen EA, la cantidad de fuentes emisoras que se pueden caracterizar son de muy amplio espectro.

2.2 EA como método de ensayo no destructivo

La EA se utiliza como técnica de END para el control de tanques a presión y de almacenamiento de sustancias, control de estructuras, análisis de fallas en materiales de construcción, control de procesos de desgaste y rozamiento, detección de xilófagos en madera, lubricación de máquinas, etc. Se la denomina una técnica pasiva debido a que no se efectúa ninguna excitación en el elemento a estudiar como ocurre con el ultrasonido o los rayos X, pero debemos tener en cuenta que para que haya EA debe existir una sollicitación de cualquier origen (mecánica, química, electromagnética, etc.) sobre el material. Los sensores de EA no detectan deformaciones cuasi estacionarias o estáticas así como tampoco de muy alta frecuencia. La EA difiere fundamentalmente en dos aspectos con otros métodos END. El primero es que la señal (onda elástica) se origina en el material examinado y el segundo es que la EA detecta movimiento y no discontinuidades geométricas [Pollock (2003)], razón por la cual la EA es un buen método para ser complementado con otras técnicas de END.

2.3 Fuentes de EA

Las fuentes de EA como la deformación plástica, el crecimiento de fisuras, el movimiento de dislocaciones, rotura de fibras, etc., causan cambios transitorios de tensión y deformación en un cuerpo elástico haciendo que se produzca una radiación de ondas elásticas. De alguna manera, las señales de EA son portadoras de información sobre las características dinámicas de tales procesos. Los modelos de fuente estática estudian como se distribuye la energía producida por una fuente para generar ondas

elásticas. En general la energía emitida por una fuente se puede distribuir entre energía superficial (a modo de ejemplo: creación o desplazamiento de fisura), energía de deformación de la red y generación de calor por deformación plástica. Solo una pequeña fracción de la energía disponible se irradia como ondas elásticas transitorias de EA que finalmente pasan a energía térmica. La idea del modelo estático es poder relacionar los mecanismos de la emisión con los procesos que las provocan a partir de la medición de la energía de EA. Esto sería posible si se conociera como se distribuye la energía en los diferentes mecanismos pudiéndose así estimar la energía de la fuente, cosa que en la práctica no es tan simple. La fracción de energía irradiada depende de diversos factores como el proceso de emisión (fuente) y de las propiedades y morfología del medio de propagación. Finalmente la proporción de energía emitida que alcanza al sensor es una convolución entre la fuente, el material y las características del sensor.

Históricamente se han realizado varias modelizaciones de fuentes dinámicas de EA, en ellas se considera que la EA se genera a partir de mecanismos de relajación, basados en masas y resortes. También se realizaron modelos donde se supuso que al igual que las cargas eléctricas aceleradas, las dislocaciones al acelerarse irradian en el medio un campo de oscilaciones elásticas (analogía de Eshelby, 1962). Posteriormente se realizaron analogías con modelos usados en sismología los cuales utilizan la función de Green.

2.3.1 Dislocaciones como fuentes de EA - Deformación Plástica

El movimiento de dislocaciones es el principal mecanismo de deformación plástica de los metales y otros sólidos cristalinos. Usualmente la energía total de la deformación se divide en una parte elástica que es reversible, y otra energía que es llamada trabajo plástico de deformación. Esta representa gran parte de la energía térmica por la generación de un gran número de fonones que atraviesan la red debido al pasaje de las dislocaciones por la red cristalina. El cambio de la energía con la variación de las configuraciones de dislocaciones puede ser considerado como posible fuente de EA. Solo una pequeña parte de la deformación plástica es guardada en la red cristalina como campos residuales de deformación de los arreglos de dislocaciones. La mayor parte del trabajo realizado se transforma en un aumento de la temperatura del material debido al movimiento de las dislocaciones que entregan energía de vibración a los átomos que cruzan a través de la red cristalina.

2.3.1.1 Estimación de la detectabilidad de la EA producida por las dislocaciones

Wadley y Scruby (1981) realizaron un cálculo de la detectabilidad de las inclusiones donde relacionaron la amplitud pico del desplazamiento de la superficie de un material isótropo por el arribo de una onda longitudinal debido al crecimiento de un lazo de dislocaciones. Se supuso que este lazo estaba ubicado a una distancia D del epicentro a 45 grados de la normal a la superficie y creciendo a una velocidad constante v, desde el cero al radio final R.

La amplitud pico se calculó como:
$$U = (b \cdot r \cdot v \cdot C_t^2) / (DC_l^3)$$

Donde b es el vector de Burgers, y C_l y C_t son las velocidades de onda en sentido longitudinal y transversal.

Si aplicamos este modelo al cálculo de una dislocación en aluminio donde típicamente $C_l=6400$ m/s, $C_t=3200$ m/s, $b=2,9 \times 10^{-10}$ m, con una velocidad de la dislocación de 200 m/s, además encontrándose la fuente a 4 cm del epicentro y considerando finalmente que el lazo de dislocaciones crece hasta un radio de 4 mm de diámetro (correspondiente a la dimensión de un monocristal) el desplazamiento resultante en la superficie del material es de 1×10^{-13} m. Teniendo un material policristalino (común o de calidad comercial), donde la distancia de deslizamiento de la dislocación generalmente no excede los 20 ó 40 mm, es muy poco probable detectar el movimiento de una sola dislocación, sin embargo si es posible detectar el movimiento cooperativo de dislocaciones (avalancha de dislocaciones).

Los mecanismos que emiten ondas elásticas y que involucran dislocaciones son variados. Como se mencionó anteriormente la relajación de un campo de tensiones elásticas, la radiación emitida por una

dislocación acelerada, las fuentes de Frank y Read, la aniquilación de dislocaciones, producen EA que puede ser detectada siempre y cuando la energía liberada sea lo suficientemente grande para que pueda ser captada por el sistema de EA. En general, los sucesos que involucren grandes números de dislocaciones serán más fácilmente detectados que los eventos que sucedan en forma puntual, aunque también se debe considerar que ante grandes deformaciones plásticas, la EA puede decrecer o anularse debido a la gran cantidad de dislocaciones las cuales se traban entre sí o con dislocaciones de foresta, reduciendo así la magnitud de los desplazamientos o deteniéndolas por completo. Este fenómeno se conoce como endurecimiento por trabajado. En la Fig. 2.1 se puede observar una curva típica de un ensayo de tracción (curva tensión – deformación) conjuntamente con la tasa de emisión de EA en función de la tensión aplicada donde se puede apreciar el gran incremento de EA justo en la zona de fluencia del diagrama Tensión- deformación hasta los comienzos de la deformación plástica. Luego durante el resto de la deformación plástica la EA es casi nula. [Miller y otros (2005)].

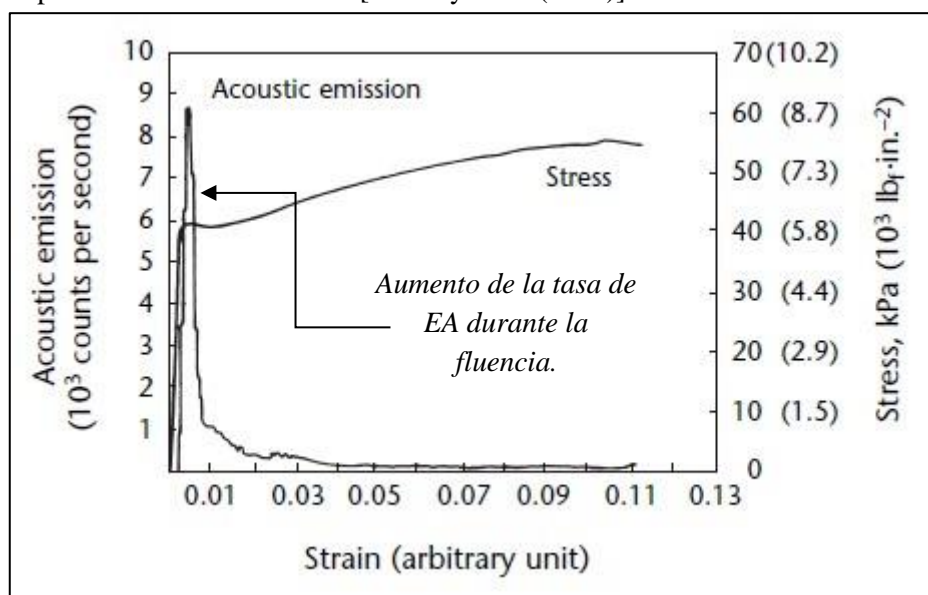


Fig. 2.1 Curva tensión-deformación y EA asociada al mismo ensayo [Miller, Hill y Moore (2005)]

La relación entre la EA y la deformación dependerá de factores que afecten el deslizamiento como la orientación cristalina, la energía de falla de apilamiento, la composición, o la temperatura.

Existen trabajos realizados por varios autores los cuales indican que existe una relación entre las ondas elásticas y la dinámica del proceso que se estudian, mencionando también que los procesos de EA suceden de forma estocástica [Grabec (1980)].

Otro factor que influye sobre la EA es el tamaño de grano, y lo hace en forma variada, para casos tratados por diferentes investigadores, la EA aumenta, disminuye o no se altera con el tamaño de grano debido a la acción de efectos cooperativos o cancelativos.

2.3.2 EA por maclado

Durante el maclado de un material se produce un movimiento cooperativo de átomos, donde cambian la orientación cristalina creando una imagen especular con respecto a la sección no maclada. Dicho movimiento a pesar de ser menor que las distancias interatómicas, liberan suficiente energía en un reducido período de tiempo haciendo que sean excelentes fuentes de EA. Ciertos materiales como el zinc o estaño producen EA en el rango audible por efecto del maclado.

2.3.3 EA por variación de dominios magnéticos-EMA-Emisión Magneto Acústica

Para materiales ferromagnéticos como los aceros al carbono, en el período elástico, existe EA producida por el movimiento de las paredes de los dominios ferromagnéticos del material. La aplicación de una tensión tiende a alinear estos dominios magnéticos en una dirección determinada produciendo ondas

elásticas detectables. Considerando que en una estructura los dominios se encuentran estables, y que al aplicar una tensión se produce el movimiento simultáneo de gran cantidad de átomos ubicados en las paredes de los dominios que cambian de orientación, puede utilizarse la EMA para caracterizar tratamientos termo mecánicos como recocidos, laminados o diferentes deformaciones plásticas en aceros al carbono [Piotrkowski y otros (2010), Kikuchi y otros (2011)].

2.3.4 EA en los diferentes procesos de fractura

Como se mencionó anteriormente el crecimiento de fisuras provoca EA debido a la liberación de energía a medida que la fisura se propaga. Si esta liberación energética es grande y rápida como en el caso de una fractura frágil, se generan ondas elásticas de gran amplitud que llevan con sí una parte importante de la energía de la fuente. Si la liberación de energía es lenta como en el caso de fisuras dúctiles, gran parte de la energía va a la región de la punta de la fisura y es utilizada para activar dislocaciones que producen una deformación plástica y hacen que la propagación de la misma no sea catastrófica. De esta manera, la energía involucrada con la irradiación de ondas de EA es menor. Existen autores que han observado que la amplitud de la EA está relacionada con la variación de la energía liberada y no con su valor. Por lo tanto una fractura frágil en general producirá EA detectable mientras que una fisura dúctil puede o no emitir señales detectables.

2.3.4.1 EA en procesos de Fractura frágil transgranular e intergranular.

Los procesos de fractura frágil pueden ocurrir en una variedad de materiales, desde los cerámicos, materiales compuestos y aceros. En el caso particular de los aceros, esta puede suceder cuando se los solicita a temperaturas por debajo de la transición dúctil-frágil haciendo que la fisura se propague a través del grano (transgranular) por los planos de clivaje (que son los de menor energía) y con muy poca deformación plástica. La propagación se produce de manera rápida y en un muy corto período de tiempo, liberando energía en el proceso que puede ser detectada por el sistema de EA.

En las fracturas de tipo intergranular, los niveles de EA son generalmente más altos que en la fractura por clivaje. La fractura intergranular propaga a través de los bordes de grano. Estas zonas que son de alta energía debido a que son los límites entre granos y que en principio tienen diferente orientación cristalina, se suelen encontrar los elementos segregados durante o posteriormente a la solidificación que pueden contribuir a la fragilización y nucleación de fisuras.

2.3.4.2 EA en procesos de fractura dúctil

La detectabilidad de la EA producida por procesos de fractura dúctil es muy variable, pudiendo ser alta, baja o nula, dependiendo de los distintos mecanismos de relajación de la energía de deformación. Para aceros de alta resistencia, existe EA en el período de expansión de la zona plástica, aunque la mayor parte de la actividad de EA ocurre en el último 20 % de la deformación. En aceros de baja resistencia la mayoría de la actividad ocurre en el período de expansión de la zona plástica, aunque las fisuras se propagan de manera silenciosa y son difícilmente detectables. Como se explicó anteriormente, esto sucede porque su propagación es más lenta, con respecto a una fractura frágil, debido a que utilizan gran parte de su energía en deformar plásticamente la región adyacente a la punta de la fisura en vez de liberarla de forma catastrófica y propagarse como lo hace la fractura frágil.

Un mecanismo de emisión por fractura dúctil ocurre por ejemplo, cuando al cargar un material, se comienzan a concentrar tensiones alrededor de algunas de las inclusiones presentes produciendo fisuras y desuniones. Consecutivamente, la zona entre las inclusiones comienza a sufrir deformación plástica, donde a su vez se nuclean huecos secundarios que se comienzan a unir y forman una grieta cuyo tamaño es el de la distancia correspondiente a las inclusiones como se observa en la Fig. 2.2. [Miller y otros (2005)]




Fig. 2.2 Ejemplificación de micro-mecanismo relacionado el crecimiento de fracturas dúctiles. [Modificado de NDT Handbook (2005)]

Para materiales de baja resistencia a la fluencia y alta capacidad de endurecimiento por trabajado el crecimiento de fisuras es de baja velocidad y poco energético, lo que hace prácticamente indetectable su crecimiento y avance. Para materiales de alta resistencia y baja capacidad de endurecimiento por trabajado aparece una prematura coalescencia de los huecos por corte a velocidades no despreciables y en cortas distancias (distancia entre inclusiones) que funcionan como fuentes de EA detectable [Miller y otros (2005)] En la Fig. 2.3 se puede observar un esquema de clasificación de la detectabilidad de las fuentes en base al área involucrada en la fisura y la velocidad de propagación de esta. El umbral demarcado en línea de trazos limita de la zona de detectabilidad.

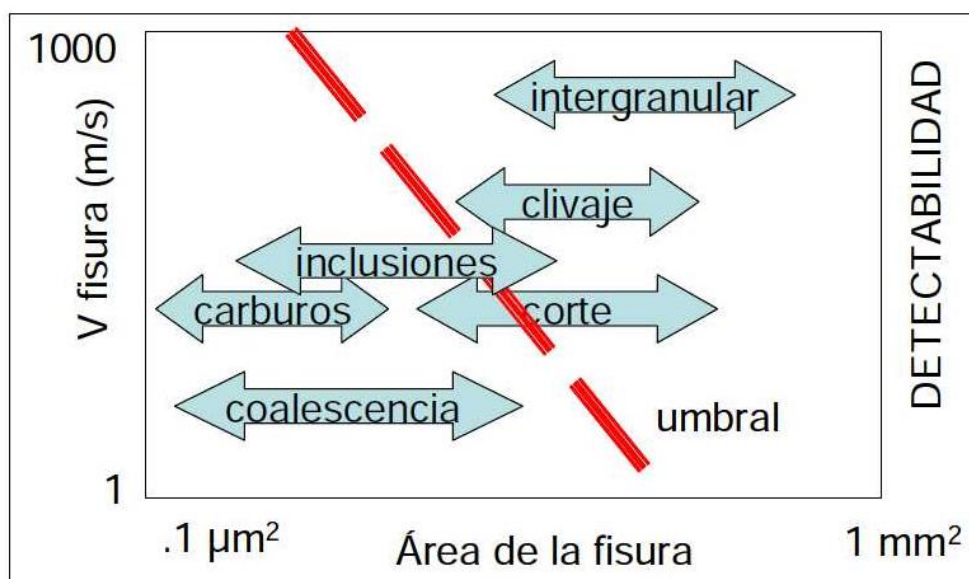


Fig. 2.3 Relación de detectabilidad, velocidad de propagación de la fisura y el área. [Gómez (2012)].

2.3.4.3 *EA por fractura de inclusiones y precipitados*

Las fracturas de inclusiones o precipitados pueden darse de manera frágil, liberando suficiente cantidad de energía en el proceso como para que puedan ser detectadas. Debido a que poseen propiedades elásticas diferentes con respecto a la matriz que las rodea, las tensiones se concentran tanto en ellas como en las interfaces entre la inclusión o precipitado y la matriz que lo rodea. La EA dependerá de los factores conformantes del material, tamaño y geometría de los elementos involucrados.

En materiales base Fe, posibles mecanismos emisores de EA son a modo de ejemplo la fractura de carburos (escasamente detectable) o la descohesión/fractura de inclusiones de MnS, siendo esta última una fuente muy importante de EA en aceros comerciales. El nivel de emisión dependerá principalmente del contenido de azufre y de la orientación del espécimen respecto del sentido de laminación.

En aleaciones no ferrosas como el Al, la fractura de inclusiones genera gran cantidad de EA. Existe un abundante número de trabajos que estudian la EA con respecto a la morfología y la composición de las inclusiones del material, no habiendo un comportamiento uniforme entre estas variables, referente al nivel de EA y su detectabilidad.

2.3.5 *EA por procesos de fricción*

En los procesos que involucran fricción se asume que coexisten varios efectos combinados como deformación y barrido de asperezas, arrastre de partículas atrapadas y descohesión del material. A su vez estos procesos dependen de una gran cantidad de factores como los materiales involucrados, las condiciones de lubricación, las condiciones de operación, la topografía de la superficie y otros [Jiaa y Dornfeld (1990), Baranov y otros (2007)]. Existen mecanismos de fricción que producen eventos que disipan la energía de la deformación. Estos pueden ser generación, movimiento e interacción de dislocaciones, transformación de fase inducida por tensión o maclado, deformación anelástica asociada con irregularidades geométricas y termoelasticidad. En todos los casos, parte de la energía liberada en el material es en forma de ondas elástica que podrán ser detectadas en la superficie por un transductor. Otros procesos asociados a la fricción y que generan EA son las interacciones elásticas e impactos, golpes impulsivos dados por partículas y residuos, micro vibración excitada por adherencia-deslizante (“stick-slip”) en la interface de las dos superficies en rozamiento. En los ensayos denominados punta sobre disco o “pin on disk test” donde una punta se coloca sobre un disco que gira a un determinado número de RPM en condiciones establecidas (lubricación y material), se encontró que la EA estaba relacionada con la disipación de energía de la fricción y que era proporcional al área efectiva y a la velocidad de deslizamiento de las superficies involucradas elevadas a un exponente fraccional que ajustaba a los datos experimentales, esta relación se halló para el parámetro RMS de la señal, por lo cual este parámetro sería un buen indicador del desgaste. Existen variada cantidad de trabajos que estudian procesos de fricción en diferentes características, por ejemplo ensayos “block on ring sliding test”, ensayos en herramientas de corte, ensayos entre pares metálicos o polímeros–metales, etc., en los cuales se pudieron establecer relaciones entre la EA, la fuerza de fricción y la velocidad del deslizamiento de las superficies que intervienen o caracterizar según la amplitud de la señal, la adherencia de las superficies debido a que producen señales tipo explosión (temporalmente determinadas).

2.3.6 *Otras fuentes de EA*

Existen otras fuentes de EA aparte de las señaladas que afectan a los materiales, en la Fig. 2.4 se puede observar diversas fuentes relacionadas a los materiales metálicos. Ellas son la disolución del metal, la rotura de películas, la liberación de gases, la corrosión bajo tensión y la cavitación, produciendo todas ellas un deterioro del material. Para materiales compuestos basados en fibras de vidrio o de carbono con diferentes resinas epoxi, existen distintos tipos de fuentes de emisión acústica tales como: rotura de la matriz, desunión de fibras respecto de la matriz, rotura de fibras y delaminación, cada una de ellas muy

bien identificables según la forma de la onda de EA producida. [T. Philippidis y otros (1998), N. Godin y otros (2005)]




Fig. 2.4 Diversas fuentes de EA en materiales metálicos. [Gómez (2012)]

2.4 Sensores de EA

Se denomina “sensor de EA” a aquel transductor que se utiliza para la detección de señales de EA en el campo de los END [IRAM (2005)]. Estos transductores convierten el movimiento (ondas elásticas), en una tensión eléctrica que es la señal de EA que será acondicionada, registrada y analizada. Los sensores se acoplan a la superficie de la pieza detectando la pequeña variación dinámica del desplazamiento de la superficie. Existe una gran variedad de sensores que dependen de diferentes principios físicos para la transducción, variando también en formas y tamaños. En EA los transductores más usados son piezoeléctricos, capacitivos e interferométricos. Estos serán descritos a continuación.

2.4.1 Sensores Capacitivos

Los sensores capacitivos son principalmente de uso de laboratorio como patrón de calibración, estando estos implementados bajo normas internacionales para calibración de sensores [ASTM E 1106]. El principio de funcionamiento está basado en la variación de la capacidad de un condensador de placa móvil, el cual al variar la distancia entre placas debido a la onda elástica, variará la capacidad produciendo una diferencia de potencial en un circuito que será la señal de EA. Tienen un gran ancho de banda, produciendo señales eléctricas que representan fielmente el desplazamiento de la superficie del material estudiado.

2.4.2 Sensores interferométricos

Estos sensores son sistemas que miden el desplazamiento de una superficie en base a interferometría laser, es decir que miden la diferencia de fase producida por la variación de la distancia entre la fuente emisora del láser y la superficie de estudio donde se refleja. Las principales ventajas de estos dispositivos es la medición a distancia del objetivo, muy útil a la hora de realizar ensayos en componentes a alta temperatura, o en ambientes irradiados o corrosivos, siendo sus desventajas el costo y la difícil implementación del sistema.

Tabla 2.1 Sensibilidad y rango de frecuencias de trabajo para diferentes sensores. [Gómez (2012)]

Principio de funcionamiento	Sensibilidad de desplazamiento	Rango de frecuencia
Piezoeléctrico resonante	10^{-14} m	0,1-0,8 MHz
Piezoeléctrico amortiguado	10^{-13} m	0,1-2 MHz
Capacitivo	10^{-12} m	0-50 MHz
Interferométrico	10^{-10} m	0-10 MHz

2.4.3 Sensores piezoeléctricos

Los sensores de tipo piezoeléctrico son los más utilizados para la detección de las ondas elásticas en el rango de los ultrasonidos debido a su fácil implementación, muy alta sensibilidad y bajo costo. Estos se fabrican de diferentes materiales como ser zirconato titanato de plomo (PZT) o también materiales poliméricos (PVDF).

Cuando se produce un evento de EA, la onda elástica se transmite por el cuerpo hasta la superficie de la pieza y al sensor, atravesándolo y produciendo una deformación que induce un reordenamiento de las cargas en la estructura del piezoeléctrico. Esto genera una diferencia de potencial eléctrico que es la señal de EA, esta salida eléctrica del transductor ($V(x,t)$), es la resultante de la convolución entre el desplazamiento de la superficie de la pieza ($Y(x,t)$) y la función respuesta del transductor ($T(t)$). Estos sensores tienen ciertas desventajas ya que son de un restringido ancho de banda lo cual condiciona el rango de aplicación de la EA en la industria (30 kHz a 2 MHz) y la pérdida de las características de piezoelectricidad por encima de la temperatura de Curie (200°C-300°C).

La geometría de los piezoeléctricos difieren en tamaños y formas, estas características geométricas definen la función de transferencia para un material dado. El espesor del material piezoeléctrico está relacionado con la frecuencia fundamental de resonancia y sus sucesivos armónicos. El diámetro está ligado a la sensibilidad, que cuanto mayor sea, mayor será la sensibilidad. Sin embargo se debe considerar el “efecto apertura”, que en el caso de ondas transversales cuya longitud de onda sea comparable al diámetro del sensor, pueden producir efectos espurios por la existencia de puntos dentro del sensor que se encuentren en distintas fases y sumen o cancelen sus efectos. Por lo general los sensores de EA están diseñados para responder a las componentes normales de movimiento. Aunque las ondas que se propaguen por el material sean compresivas o de corte, poseen por lo general una componente normal a la superficie que será detectada. Existen también sensores que pueden captar únicamente las componentes transversales de una onda elástica, estos se construyen por ejemplo con cristales de cuarzo cortados en direcciones cristalográficas específicas. En la Fig. 2.5 se puede apreciar un esquema detallando la conformación de un sensor piezoeléctrico.




Fig. 2.5 Esquema de construcción de un transductor piezoeléctrico [modificado de Miller, Hill y Moore (2005)].

2.4.3.1 *Sensores piezoeléctricos de banda ancha*

Su rango de respuesta en frecuencia es ancho, de 100 kHz a 1 MHz. Son de alta fidelidad y en general se utilizan para investigación en laboratorio, ya que permiten (por su ancho de banda) realizar análisis en frecuencia (Fourier u onditas), siendo los más apropiados para estudiar las fuentes de EA.

2.4.3.2 *Sensores piezoeléctricos sintonizados*

Estos sensores utilizan la máxima sensibilidad de los piezoeléctricos debido a que su rango de trabajo está situado en o muy cerca de las frecuencias de resonancia naturales del cristal. Los rangos de frecuencia son muy variados y tienen un pico de sensibilidad donde trabajan en óptimo estado. En la Fig. 2.6 se puede observar un certificado de calibración donde se puede detectar que el pico máximo de sensibilidad se encuentra alrededor de los 150 kHz, este modelo de sensor sintonizado es ampliamente utilizado en control de tanques y estructuras.

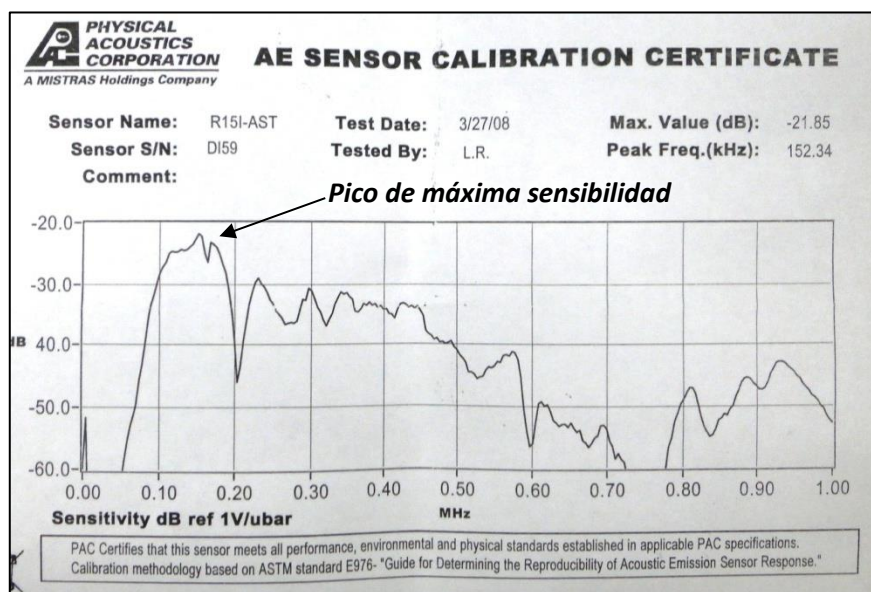


Fig. 2.6 Respuesta en dB del sensor de EA en función de la frecuencia.

2.4.3.3 *Sensores piezoeléctricos diferenciales*

Estos sensores están preparados para ser conectados de manera diferencial, con el objetivo de poder eliminar el ruido en común, los mismos son conectados a preamplificadores diferenciales especialmente diseñados y deben contar además con cables de tipo coaxial diferencial.

2.4.3.4 *Sensores piezoeléctricos con preamplificador integrado.*

Estos sensores cuentan con un preamplificador incorporado dentro de la armadura del sensor siendo dimensionalmente algo mayor que los convencionales y se encuentran disponibles en una amplia gama de frecuencias donde los más comunes utilizan una ganancia de 40 dB.

2.4.3.5 *Sensores piezoeléctricos miniatura*

Estos sensores se utilizan en condiciones donde el tamaño y el peso sean críticos para la operación, debido a sus reducidas dimensiones (de 3 a 10 mm de diámetro y menos de 10 gramos de peso) poseen una sensibilidad menor que los convencionales aunque se ven favorecidos por el efecto apertura.



Fig. 2.7 De izquierda a derecha: Sensor miniatura banda ancha, sensor con preamplificador sintonizado, sensor con preamplificador banda ancha.

2.4.4 Otros sensores

Existen otros sensores con aplicaciones más específicas a los ya citados, por ejemplo para condiciones de trabajo que superen las temperaturas de Curie. Se pueden hallar sensores que trabajen en rangos de temperatura de hasta 500°C y con amplios espectros de frecuencia. También existen sensores móviles que permiten hacer una inspección dinámica de la superficie así como sensores sumergibles que pueden ser instalados en tanques de almacenamiento de líquido y plataformas off shore.

2.5 Instrumentación de la EA – Sistema de EA

Un sistema de EA cuenta con varios pasos que deben ser ilustrados para poder entender el funcionamiento del equipo, sus ventajas y limitaciones. En esta sección pasaremos a detallar los componentes de un sistema de EA.

En la Fig. 2.8 se puede apreciar un esquema que detalla una fuente emisora de EA generando la onda elástica que será captada por el sensor y convertida a señal eléctrica para luego ser preamplificada antes de ingresar al equipo de EA el cual procesará y almacenará la señal.

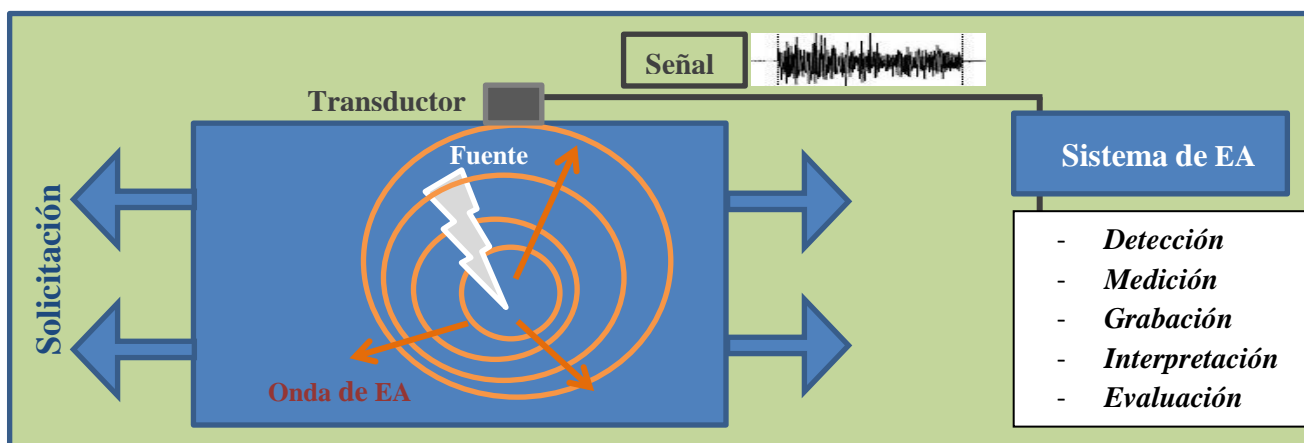


Fig. 2.8 Esquema de conjunto fuente y sistema EA.

Primeramente se debe considerar que la onda elástica pasa desde la superficie del material hasta el sensor mediante un elemento acoplante, que tiene la función de equiparar la impedancia acústica. De esta manera se logra que la energía de la onda elástica sea efectivamente transmitida entre las dos superficies. Según la fórmula $I = \rho \cdot V$, donde I =impedancia Acústica, ρ es densidad y V velocidad de propagación de la onda en el material considerado.

De no existir este acoplante, en las interfaces material/sensor queda una la capa de aire remanente que produce un gran salto de impedancia haciendo que una importante parte de la energía de la onda no logre salir del material y sea reflejada. En la Tabla 2.2 figuran diferentes sustancias que pueden ser utilizadas como materiales acoplantes y sus impedancias respectivas.

Tabla 2.2 Comparación de propiedades de diferentes acoplantes [Gómez (2012)].

Sustancia	Densidad en 10^3 Kg/m ³	Velocidad de ondas longitudinales en m/s	Velocidad de ondas transversales en m/s	Impedancia Acústica en 10^6 Kg/m ² .s
Aceite (SAE 20 a 30)	0,89-0,961	1,74	-	1,5-1,7
Agua destizada (20° C)	1	1,483	-	1,48
Agua etílico (20° C)	0,79	1,17	-	0,92
Glicerina (20° C)	1,26	1,92	-	2,4
Aire (20° C)	0,0012	0,33	-	0,00043

Para el caso de que se quiera transmitir ondas transversales, existen acoplantes sólidos tipo epoxi, donde se debe observar que no produzcan EA debido a microfracturas cuando están adheridos a las piezas de estudio. Cada acoplante tendrá su rango de temperatura de operación y se deberá realizar antes de los ensayos, mediante algún método normalizado (Ver Apéndice 1), la correcta verificación de la adhesión de los mismos.

2.5.1 Preamplificadores

La señal de EA producida por el piezoeléctrico es de baja amplitud y si la extensión del cable entre la fuente y el equipo es prolongada, la señal sufrirá una atenuación considerable con la consecuente pérdida de información debido al descenso de la relación señal-ruido. Para evitar este fenómeno, a una distancia no superior a 1,5 m, se debe colocar un preamplificador que además de amplificar la señal adapta las impedancias entre el sensor y la línea de transmisión, de allí la razón de los sensores con preamplificadores incorporados. Comercialmente existen diferentes niveles de ganancia (0, 20, 40 y 60 dB) siendo los de 40 dB los más comunes. En la Fig. 2.9 se muestran algunos modelos de estos preamplificadores. Se debe tener en cuenta que los preamplificadores son alimentados por el equipo de EA, el cual envía una corriente continua por el mismo cable coaxil por el cual recibe la señal proveniente del sensor.




Fig. 2.9. Diferentes modelos de preamplificadores comerciales.

2.5.2 Equipo de EA: Amplificador-Parametrizador y Digitalizador.

En la actualidad estos equipos suelen ser digitales y están embebidos o conectados a una PC. Los equipos de uso industrial se componen de plaquetas con varios canales los cuales se colocan en serie sobre racks para el armado de un equipo multicanal. Existen equipos de menor envergadura para uso de laboratorio como el de la Fig. 2.10 los cuales pueden ser colocados directamente en PC convencionales ya que están

integrados en placas PCI. Los equipos de EA pueden tener varias decenas de canales dependiendo de las características del ensayo a realizar, el tamaño del componente, el material y sensibilidad requerida.



Fig. 2.10 Placa integrada PCI de EA de dos canales para PC.

Una vez que la señal llega al equipo vuelve a ser amplificada pero esta vez no para ser transmitida sino para ser procesada, estos amplificadores deben permitir el manejo de un amplio rango de frecuencias que puede ir desde los kHz hasta los MHz.

El primer paso en el procesamiento de la señal es el establecimiento de un valor umbral o filtrado por amplitud. Este umbral es un valor que establece el operador, donde se considera que todas las señales que lo sobrepasen serán consideradas como señales de EA y las que no lo hagan serán consideradas como ruido. Posteriormente las señales son filtradas analógicamente por un filtro pasa alto y pasa bajo que permite recortar en ancho de banda, esto se puede utilizar en el caso de que se deseen eliminar ruidos fuera de la frecuencia de interés de la señal. El paso siguiente es la digitalización de la señal en la cual se puede seleccionar la resolución en bits (desde 8 a 18 bits), así como la tasa de muestreo en función de las frecuencias a medir. Una vez digitalizada la señal, la información puede ser extraída de diferentes formas, mediante la determinación de ciertos parámetros representativos, formas de onda o señal completa (streaming).

2.5.3 Modo de adquisición Paramétrico - Parametrización

En los comienzos de la EA, los equipos trabajaban de forma analógica por lo que para caracterizar una onda era necesario crear de forma electrónica descriptores (parámetros) característicos que las definan. En la parametrización de la señal se pierde información pero se gana en procesamiento y manejo de datos. Una de las primeras diferenciaciones que se pueden realizar es de acuerdo al comportamiento temporal de la señal, según sea determinada o indeterminada temporalmente. Existen señales que en principio pueden no exhibir principio ni final determinado, llamadas señales continuas, y existen señales que exhiben un inicio y una finalización claramente definidos en el tiempo, las cuales suelen llamarse señales tipo *explosión* o *burst* y son pulsos transitorios. Ejemplos de estos tipos de ondas pueden verse en la Fig. 2.11. Otros parámetros evaluados son el RMS, Tiempo de subida, duración de la señal, Energía MARSE, Frecuencia Media, Energía Absoluta, etc. Estos parámetros están definidos en las normas internacionales como la ASTM 1316 [ASTM (1997b)] y NM 302 [IRAM (2005)]. Los mismos serán detallados con mayor profundidad, más adelante en el presente capítulo.

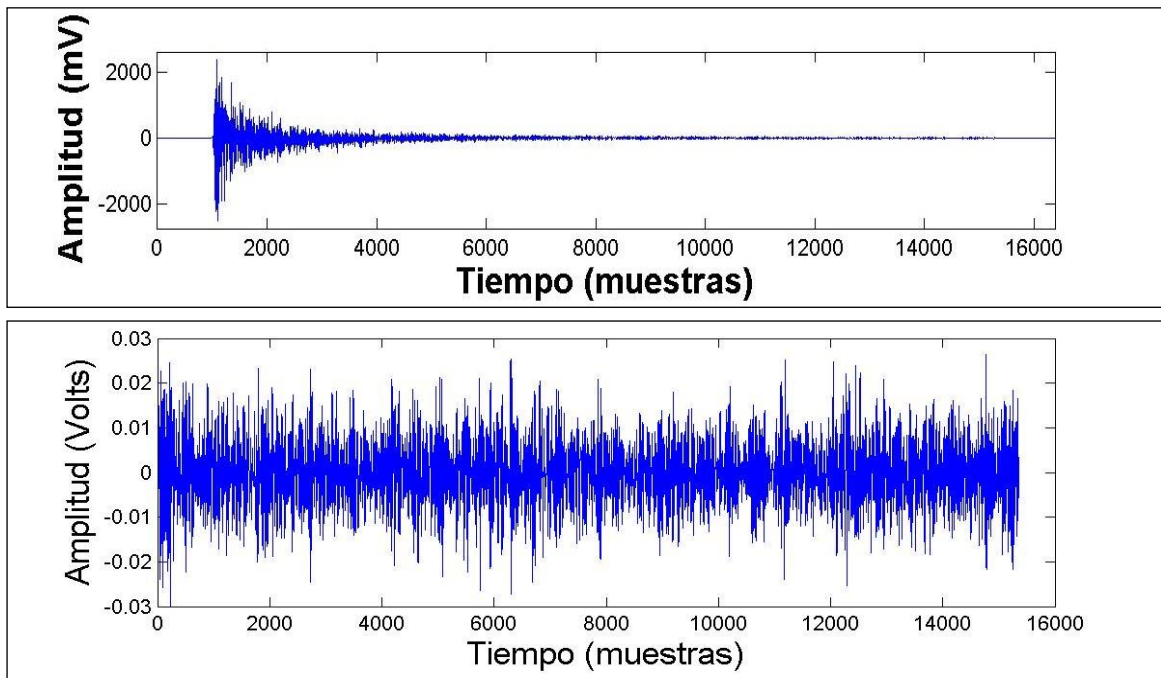


Fig. 2.11 Señal de EA tipo Burst (superior), continua (inferior) [Gómez (2012)].

2.5.4 Modo de adquisición de Formas de onda (Waveforms)

La adquisición de las formas de onda consiste en el registro digital de una pequeña porción de señal durante un período de tiempo que puede variar desde los milisegundos hasta los segundos, dependiendo de la tasa de muestreo. Este procedimiento utiliza más recursos de hardware tanto para procesamiento como para el almacenamiento de los datos. La cantidad y calidad de los datos adquiridos es superior que en el modo paramétrico.

2.5.5 Modo de adquisición Streaming

Cuando la adquisición se realiza en este modo toda la señal es digitalizada y almacenada de manera completa a tiempo real enviándola directamente al disco rígido de la máquina. Estas señales guardan toda la información recibida de la EA perteneciente al ensayo, pero debido al gran volumen de información que debe ser procesado, existen serias limitaciones que involucran espacios de almacenamiento muy grandes y manejo de archivos de enorme tamaño que restringen la utilidad de este método de adquisición.

2.5.6 Parametrización de las Señales de EA

A continuación se pretende dar a conocer los parámetros con los cuales se caracterizan las ondas de EA. Como se comentó anteriormente la primera clasificación que se realiza sobre las señales es según su comportamiento temporal. En los procesos de EA puede suponerse la existencia de ambos tipos de señales (explosión y continuas) en el mismo proceso. Más aun, las señales *continuas* pueden ser consideradas como una sumatoria de señales tipo explosión que se superponen una sobre otra creando un espectro continuo. Una vez que la señal ha sido clasificada temporalmente se pueden comenzar a definir el resto de los parámetros.

Para comenzar nuestro estudio se debe explicitar que los parámetros están definidos en principio para señales transitorias tipo explosión y luego algunos de ellos podrán extrapolarse a señales tipo continuas. El primer parámetro que se debe fijar es el valor *umbral*, que es el nivel de tensión que debe sobrepasarse para que una señal de EA sea detectada y procesada. Este umbral puede ser fijo, ajustable o flotante. Para continuar con la determinación de los parámetro se debe aclarar un término utilizado en la EA el cual es

“HIT” y que se define como la señal de EA que es registrada por el equipo y por lo tanto que ha superado el valor umbral.

Tiempo de ocurrencia (hit time): se define como el tiempo de llegada o de ocurrencia de la señal. Es el tiempo al cual se considera que comienza el hit y esto ocurre cuando supera el umbral, por lo tanto es dependiente de este valor.

Amplitud máxima o Amplitud: es el valor máximo de amplitud que alcanza la señal y está relacionado con la magnitud de la fuente y las propiedades del material. Se expresa en dB_{EA} y es uno de los parámetros que pueden servir para describir señales continuas. No depende del umbral, siempre y cuando lo supere. Los dB_{EA} se definen como:

$$dB_{EA} = 20 \cdot \log \frac{V_s}{1\mu V}$$

Donde V_s es el voltaje medido a la salida del sensor piezoeléctrico, por lo que despejando de la ecuación, si el resultado en dB es 0, entonces el voltaje de salida del sensor es de 1 mV, si es de 20 dB, serán 10 mV y si la señal tiene una intensidad de 40 dB a la salida del sensor será producto de una amplitud en tensión de 100 mV.

Duración (Duration): es el tiempo que transcurre desde que la señal cruza por primera vez el umbral hasta que lo hace por última vez. Depende de la fuente emisora, tipo y forma del espécimen, así como de las características del sensor y del valor del umbral.

Tiempo de subida (Rise Time): es el tiempo desde que la señal cruza el umbral por primera vez hasta que llega a la amplitud máxima. Depende del umbral y está relacionada con el periodo de actividad de la fuente.

Número de Cuentas (Ring Down Counting) es la cantidad de veces que la señal cruza el umbral, depende del umbral y está relacionada con la amplitud.

Energía MARSE: Es el área medida bajo la envolvente de la señal rectificada (*Measured Area under Rectified Signal Envelope*). Depende del tiempo y por lo tanto del umbral además de la amplitud.




Fig. 2.12 Detalle de los parámetros de EA. [Modificado de Gómez (2012)]

Valor Cuadrático Medio o RMS (Root Mean Square): Este parámetro se define matemáticamente como:

$$RMS = \sqrt{\frac{1}{T} \int_{t_0}^{t_0+T} [V(t)]^2 dt}$$

Donde V es el voltaje medido. Este parámetro sirve para caracterizar señales continuas. Por definición del RMS, la energía contenida en la señal puede estimarse como proporcional al cuadrado de este parámetro en el intervalo de tiempo considerado:

$$\Delta E \propto (RMS)^2 \Delta t$$

Energía Absoluta (Absolute Energy), se define matemáticamente como:

$$E_e = \frac{1}{R} \int [V(t)]^2 dt$$

Donde V es el voltaje de salida del sensor y R una resistencia de referencia.

Frecuencia Media (FM): Es un parámetro secundario y se define como el cociente entre el número de cuentas y la duración del Hit.

Potencia Media (PM): Este parámetro secundario se crea a partir del cociente entre la Energía MARSE y la duración del hit. Debido a que es independiente del tiempo este parámetro puede ser utilizado en señales de tipo continuo.

Existen además otros parámetros secundarios pueden ser encontrados en la bibliografía [Philippidis y otros (1998)] como *Angulo de decaimiento o DAN (Decay Angle)* que es el resultado dividir la Amplitud sobre la duración de la señal, o el área *Subida – Decaimiento o RDA (Raise-Decay Area)* el cual es producto de dividir el tiempo de subida sobre la Duración. De similar otros parámetros son calculados como las cuentas hasta el pico máximo de la señal sobre las cuentas totales o el número de cuentas de decaimiento de la señal respecto del número de cuentas de hasta el pico máximo. Todos estos parámetros serán útiles o no en la medida que sean descriptores característicos del proceso que se está estudiando, lo que demarcara el beneficio de su utilización.

Tabla 2.3 Comparación de parámetros de EA con su resolución, unidades y rango [Gómez (2012)].

CARACTERÍSTICA	RESOLUCIÓN	UNIDADES	RANGO
Tiempo del hit	0,250	Microsegundos	0-407 días
Amplitud	1 dB	1 dB	10-100 dB
Energía (PAC)	1 cuenta	10 μ V.s/cuenta	0-65535
Numero de cuentas	1 cuenta	cuentas	0-65535 cuentas
Tiempo de subida	1 μ s	microsegundos	0-65,5 ms
Duración	1 μ s	microsegundos	0-1000 ms
Energía absoluta	1 cuenta	$9,31 \times 10^{-22}$ Joules	$2,61 \cdot 10^{-8}$ J
Fuerza de la señal	1 cuenta	3,05 pV.s	$0-1,31 \cdot 10^8$ pV.s
Cuentas hasta el pico	1 cuenta	cuentas	0-32768 cuentas
Potencia parcial	1 cuenta	% de la potencia total	0-100 %
RMS	0,0002V	V	0-6 V
ASL	1 dB	1 dB	0-100 dB
Umbral	1 dB	1 dB	14-99 dB

El equipo de EA puede ser configurado para que muestre estos parámetros en tiempo real, es decir a medida que se realiza el ensayo. En la Fig. 2.13 se puede observar la captura de la pantalla de uno de los ensayos realizados para esta tesis donde se muestran algunos parámetros de EA, además de la entrada de parámetros externos y en la parte inferior una lista de registro de cada uno de los hits obtenidos durante el ensayo.

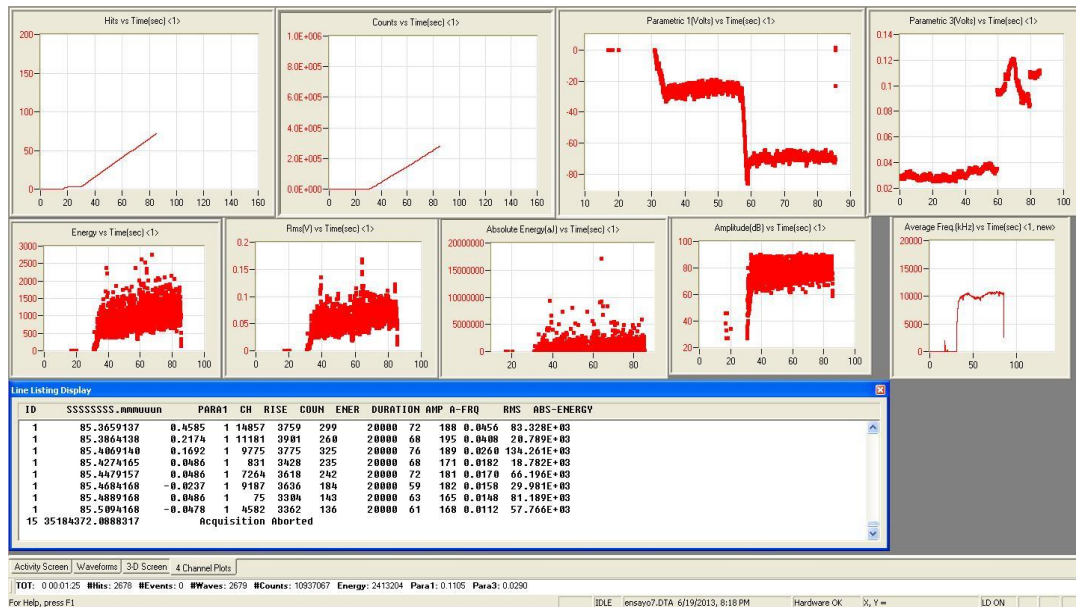


Fig. 2.13 Detalle de la visualización de los parámetros de EA en el equipo tomado de un ensayo real.

Además de los parámetros de EA, la placa de EA cuenta con entradas analógicas para parámetros externos, es decir parámetros independientes que pueden sincronizarse con la EA, ya que se reciben de manera paralela. En el presente trabajo como parámetro externo se registró la Fuerza de Avance (FA) en todos los ensayos de taladrado y cuyas unidades son en [Kg].

Los parámetros anteriormente mencionados son los que el equipo registra y almacena. Una vez finalizado el ensayo se procede a la descarga de estas listas de información para su posterior procesamiento y estudio.

2.6 Fuentes de ruido que pueden afectar la EA y tratamiento de los mismos.

Existen distintos tipos de ruidos que pueden afectar las mediciones según su procedencia. Estos pueden ser confundidos como parte de las señales de EA pudiendo añadir falsa información sobre el proceso que se desea estudiar. Los ruidos de tipo electromagnéticos generados por componentes eléctricos y electrónicos (ruido blanco) tanto pertenecientes al equipo de medición de EA como externos a él. En el caso de monitores, relays, lámparas y tubos fluorescentes, señales de radiofrecuencia y otros deben ser cuidadosamente examinados y relevados antes de comenzar las mediciones. Existen también fuentes de ruido pertenecientes a componentes electrónicos como ventiladores, o piezas mecánicas móviles que emiten ondas elásticas detectables. En ambientes industriales las condiciones de ruido son más exigentes ya que coexisten fuentes de ruido mecánico provenientes del proceso de producción sumado al funcionamiento de las máquinas que se pretenden estudiar. Si además se le adiciona todo el ruido eléctrico producido en zonas aledañas proveniente de soldadoras, luminarias, fuentes conmutadas, interruptores eléctricos hacen que la evaluación del nivel de ruido antes de comenzar con los ensayos sea una tarea imprescindible para minimizar errores y maximizar la relación señal ruido a la hora de ensayar un componente.

Muchas veces, a pesar de las precauciones que se tomen al respecto, existen fuentes de ruido que no se pueden eliminar, entonces deben ser tomadas acciones correctivas para minimizar el impacto de las mismas sobre el ensayo. Por ejemplo, en el caso de ruidos mecánicos se puede aislar los componentes que se van a ensayar con materiales que tengan mucha atenuación (plásticos, gomas etc.). De esta manera se impide la llegada de ruidos espurios a la zona a evaluar. En caso de ruidos de tipo eléctrico se puede recurrir al concepto de jaula de Faraday donde se rodea a la pieza de estudio de una cubierta conductora conectada a tierra, así toda la radiación de las ondas electromagnéticas será absorbida por la cubierta y descargada a tierra, no pasando por el sensor. En el caso de ensayar componentes metálicos es importante que estos estén correctamente conectados a tierra para que no funcionen como antena. Si el ruido está

identificado y cuantificado, existen diferentes métodos de separación de la señal, como el filtrado en amplitud, manejando los niveles del umbral, o filtrado en frecuencia utilizando los filtros pasa bajo, pasa alto y pasa banda. Estos filtros pueden ser de tipo físicos colocados antes de que la señal ingrese al equipo o pueden ser fijados en el software del equipo de EA. Los programas de estos equipos permiten realizar otros filtrados a partir de los parámetros característicos de las señales, es decir que si las señales no cumplen con especificaciones en parámetros como el tiempo de subida, energía o duración determinada son descartadas, aunque para esto se deben conocer minuciosamente los procesos involucrados. En los casos en que los ruidos no puedan ser eliminados mediante los métodos anteriormente mencionados, se puede recurrir a realizar un análisis de la señal y eliminar de manera manual. Una forma de hacerlo es utilizando el método de los sensores guarda, mediante el cual se colocan sensores en el camino acústico de las ondas de ruido y de esta manera se caracteriza esta emisión para posteriormente extraer la señal correspondiente a dichos sensores en la etapa de procesamiento.

2.7 EA en el control y monitoreo del estado de la herramienta.

Debido a la importancia del monitoreo del estado de la herramienta durante el mecanizado, existe una amplia cantidad de trabajos que relacionan la EA con los procesos de corte en metales. Dornfeld y otros (1980), Kannatey-Asibu, Jr. y otros (1980), Saini y otros (1996), Pollock (1973) asocian el RMS de la amplitud de la señal de EA con ciertas condiciones del proceso de corte en torneado. Estos buscan generar, en base a la experimentación y al cálculo de modelos empíricos y analíticos, una relación entre las variables del proceso de corte (deformación plástica del material extraído, flujo de viruta, avance y RPM) y este parámetro de la EA. Grabec y Leskovic (1977) analizan la distribución en el espectro de frecuencias de la señal de EA y sus variaciones considerando las modificaciones de avance, RPM y profundidad de corte en torneado. Jemielniak y otros (1997) exponen que el análisis de la Kurtosis y Skewness de la distribución del parámetro RMS de la señal muestra buena sensibilidad a la rotura catastrófica de la herramienta. Roget y otros (1987) estudiaron para procesos de fresado y torneado, la relación entre el parámetro RMS y el aumento del desgaste de la herramienta conjuntamente con la rotura súbita de la misma.

Para procesos de taladrado se han utilizado los parámetros de Energía, Cuentas y RMS de la señal de EA para correlacionar la variación del diámetro de un orificio taladrado, con el estado de la broca [Everson y otros (1999)], encontrando que la energía de la EA responde satisfactoriamente a las variaciones dimensionales de los labios de la broca y por lo tanto al diámetro del orificio taladrado. Gómez y otros (2011, 2012), encontraron que el parámetro secundario, Potencia Media de la EA, y su varianza asociada pueden distinguir diferentes condiciones de desgaste en una broca de taladrado y que a su vez existe correlación lineal entre este parámetro y el torque del proceso para estas brocas. Ravishankar y otros (2000) han estudiado la EA en taladrado de materiales compuestos con fibra de vidrio y resina epoxi donde se analiza la amplitud de la señal desde la penetración hasta la salida de la broca correlacionándola con la fuerza de avance. Mascaro y otros (2005) relacionan el espectro de frecuencia durante el taladrado de materiales compuestos en fibra de carbono y resina epoxi, donde muestran que la banda de frecuencia concerniente a la rotura de la matriz y de las fibras no varía con el cambio de geometría del herramienta, la velocidad de taladrado y el avance. Además indica que la energía de la señal de la EA es sensible al desgaste de la herramienta lo que revela que eventualmente este parámetro podría ser utilizado para el control del estado de la misma.

Los trabajos anteriormente citados muestran que se puede relacionar el estado de la herramienta para una dada condición de proceso con diferentes parámetros de la EA. Las bases de estas relaciones yacen en que una variación en el estado de la herramienta produce una modificación en el proceso, que da como resultado un cambio en la EA que emana de este. Debido a lo anterior es posible pensar en generar una asociación entre la condición de la herramienta y uno o varios parámetros que evolucionen conjuntamente con el deterioro del herramienta. Por lo tanto estas variables pueden ser monitoreadas de manera continua para controlar su evolución del estado de la herramienta. Es con este fin que se encuentran múltiples

trabajos utilizando diferentes herramientas matemáticas como análisis en frecuencias, análisis de distribuciones estadísticas, correlación lineal, aplicación de inteligencia artificial y otras, para identificar y extraer parámetros de EA que sean descriptores de diferentes condiciones de proceso. De manera general todos los autores coinciden en que si bien es posible correlacionar el estado o condición del proceso con algún parámetro de la EA, se debe delimitar detalladamente el entorno en que se desarrolla el proceso de mecanizado, ya que confluyen interacciones entre muchos factores que hacen que la generación de la EA sea un fenómeno complejo de analizar. En la Tabla 2.4 figura una clasificación de algunos factores que afectan las operaciones de monitoreo de la herramienta, y que debido a lo incierto de su naturaleza se desconoce precisamente el efecto que estos producen sobre las señales de los sensores.

Tabla 2.4 Influencias sobre el proceso y el sistema clasificados por su fuentes, [Modificado de O'Donnell y otros (2001)].

Proceso	Herramienta	Sistema
		Geometría
		Desgaste
	Condiciones de corte	Material de la herramienta y recubrimiento
		Velocidad de corte
		Avance
		Profundidad de corte
		Formación y remoción de virutas
		Profundidad del taladrado
	Material trabajado	Dureza
		Variación de tolerancias dimensionales
		Cambios en el contenido de la aleación
		Inclusiones
		Operaciones precedentes
	Refrigerante	Tipo de fundición (en molde o en arena)
		Cambios en la concentración
		Variaciones de presión
	Sistema	Humano
Nivel de experticia del usuario		
Proceso de visualización		
Máquina		Otros no considerados
		Política de cambio de herramientas
Interface		Política de re-afilado de herramientas
		Variación del tipo de material
Herramienta		Variación del proveedor
		Variación del lote
		Variación de la performance del motor en función de la temperatura
Material Trabajado		Vibración de la máquina herramienta
		Cambios en la fricción o guías de deslizamiento
		Eficiencia y estado de los rodamientos
		Desalineación de los mecanismos de sujeción
		Controles de los tiempos de ciclos
	Operaciones de maquinado en paralelo	
Máquina herramienta	Interferencia eléctrica	
	Cambios en la temperatura ambiente	

El éxito de la implementación de un sistema de monitoreo dependerá en parte en la habilidad para tener en cuenta o compensar la influencia de estos factores [O'Donnell y otros (2001)]. Esto impone demandas en los futuros sistemas de control de la herramienta, que pueden ser resumidos de la siguiente manera [Byrne y otros (1995)]:

- Reducir tiempo de respuesta del sistema aumentando la confiabilidad operacional al máximo.
- Amplio rango de integración en el sistema de manufactura (incluido el operador de la máquina).
- Alta robustez y bajos costos de instalación.
- Operación amigable con mínima calibración.
- Poco requerimiento de espacio y poco o mínimo mantenimiento.

A su vez, en la parte de software y procesamiento de señales se debe considerar la obtención de un rápido y eficiente procesamiento digital de la señal, una miniaturización de los componentes y el desarrollo de sistemas híbridos (sensores, circuitos analógicos y digitales) con componentes de bajo costo.

Todo esto aplicado mediante el empleo de tecnologías que utilicen sistemas inteligentes como redes neuronales artificiales, lógica difusa, sistemas expertos, algoritmos genéticos y otros con el fin de asistir en la determinación de las relaciones entre el proceso y la información brindada por los sensores. Esto hará que los sistemas sean basados verdaderamente en el conocimiento o experiencia, y que puedan aprender y adaptarse a diferentes condiciones de proceso.

Capítulo 3

INTRODUCCIÓN A REDES NEURONALES

En el presente capítulo se busca realizar una mínima introducción a la temática de las redes neuronales. La información y bibliografía existente es muy extensa así como la cantidad de redes con diferentes propósitos y arquitecturas. Para comprender su funcionamiento básico se explicarán lineamientos generales del cálculo que pueden ser extrapolados a redes con diferentes peculiaridades. Por último, se realizará una explicación más detallada de las características de un tipo de red neuronal en particular, denominada Mapa Auto Organizado (Self Organized Map), la cual es utilizada en el presente trabajo para realizar una tarea de clasificación de las señales obtenidas en los ensayos.

3.1 Introducción

Las redes neuronales artificiales son un paradigma de aprendizaje y procesamiento automático que surgió a partir del avance en el conocimiento del funcionamiento de las neuronas biológicas. Las neuronas son células que reciben, procesan y envían estímulos eléctricos, por ejemplo, a otras neuronas. Las interconexiones entre neuronas hacen que se cree una red con la capacidad de realizar tareas de alta complejidad, como por ejemplo el procesamiento de señales. Cuando el árbol dendrítico (Fig. 3.1 a) recibe una señal eléctrica que sobrepasa un umbral determinado, manda otra señal a través del axón (Fig. 3.1 b) a los terminales axónicos. Estos se conectan a través de la sinapsis a los terminales de otras neuronas induciendo potenciales negativos o positivos según el neurotransmisor utilizado. De esta manera se puede estimular o no cierto tipo de comportamiento. La Fig. 3.1 b resume en forma muy esquemática el proceso de sinapsis (unión funcional entre neuronas) donde se observa una señal eléctrica que excita al axón el cual desprende neurotransmisores que son captados por la dendrita, está en respuesta produce una salida eléctrica que de alguna manera es proporcional a la cantidad de neurotransmisores detectados.




Fig. 3.1 a. Representación esquemática de un árbol dendrítico. b. Esquemática de la sinapsis.

Las neuronas artificiales pueden procesar gran cantidad de información, pudiendo llegar a tener entre 10^3 a 10^4 señales de entrada en una sola neurona. Estas acceden en forma paralela al núcleo de la neurona y no en serie como ocurre con el ingreso de información en una computadora, causando una mayor eficiencia en el procesamiento. La información se reúne en un núcleo y tras un cierto procesamiento sale una única señal por el axón que en cierta forma reúne las características de todas las señales de entrada y es transmitida hacia la dendrita.

El poder de cálculo de una neurona se puede incrementar colocando más cantidad de neuronas y conformando una red. Comparando estos modelos y conceptos con el caso del cuerpo humano (10^{11} neuronas aproximadamente) aún se está lejos de lograr un sistema con la misma performance. En la actualidad se pueden realizar redes de muchas neuronas artificiales, con muchas capas que permiten por ejemplo: clasificar información, aprender y encontrar patrones dentro de listados de datos, guiar vectores aeroespaciales, mejorar imágenes y construir sistemas de reconocimiento de voz entre otras aplicaciones.

3.2 Arquitectura y funcionamiento básico de una neurona

Se comenzará con la descripción del funcionamiento de una neurona que luego será extrapolado a sistemas más grandes y complejos. En la Fig. 3.2 a se observa la arquitectura más simple de una neurona con una sola entrada escalar. La entrada escalar p (dato de entrada) es transmitida a través de una conexión que multiplica este argumento por otro término escalar w que se denomina “peso” para formar el producto wp , nuevamente escalar.




Fig. 3.2 Esquema de arquitectura de una neurona. a. Sin bias. b. Con bias. [Demuth y Beale (2002)].

El producto wp es el argumento n de entrada a la función f . Luego f es la función de transferencia que toma el argumento n y produce una salida a . La neurona representada en la Fig. 3.2 b cuenta con un parámetro adicional que es un escalar b (bias) que se suma al producto wp , agregando un grado más de libertad al modelo, siendo entonces $w.p + b$ el argumento de entrada a la función de transferencia que da una salida a . En general se usa $b = 1$.

La variedad de formas que puede tener la función f (por ej. escalón, lineales y sigmoideas entre otras), hace que la red pueda resolver problemas cuya relación entre variables sea no lineal, superando a métodos tales como componentes principales (CP), análisis de factores, y otros que solamente estudian problemas lineales o parcialmente lineales.

El modelado de la red consiste en ajustar los parámetros neuronales w y b de manera de exhibir un comportamiento deseado. De esta forma la red puede entrenarse para hacer un trabajo en particular (en este caso la clasificación de diferentes casos de desgaste de herramientas). Durante el entrenamiento la red por sí sola ajusta estos parámetros hasta alcanzar un determinado resultado.

En la Fig. 3.3 se presentan algunas de las funciones de transferencia que pueden ser utilizadas. La función tipo *escalón* (*Heaviside*) (Fig. 3.3 a), hace que la salida de la neurona se limite a 0 si el argumento n es menor que 0, y a 1 si es mayor o igual que 0. Esta función se utiliza por ejemplo en Perceptrones (redes elementales) para trabajos de clasificación.

La función de transferencia lineal (Fig. 3.3 b) puede utilizarse para hacer aproximaciones lineales, o aplicada a la última capa de una red multicapa amplía su rango de salida cuando de la capa anterior proviene una salida 0-1 de una función *sigmoidea*.

La tercera función de transferencia, de tipo sigmoidea (Fig. 3.3 c) puede tener valores de entrada que oscilen entre más y menos infinito, dando como resultado salidas con valores entre 0 y 1. Estas funciones son muy utilizadas en redes de tipo retro propagación, por ser diferenciables y porque pueden tratar problemas lineales si el argumento n coincide con el rango de lineal de la función y también problemas no lineales si se trabaja en la zona no lineal (en la que cambia su pendiente) como se detalla en la Fig. 3.4.




Fig. 3.3 Funciones de transferencia. a. Escalón, b. Lineal, c. Sigmoidea [Demuth y Beale (2002)].




Fig. 3.4 Esquema de las partes lineales y no lineales de la función de transferencia Sigmoidea [Modificado de Demuth y Beale (2002)].

Luego se extiende el modelo de una neurona para un vector de entrada p compuesto por R elementos p_1, p_2, \dots, p_R , que son multiplicados por los correspondientes pesos $w_{1,1}; w_{1,2}; \dots, w_{1,R}$. El primer dígito indica a que neurona pertenece el peso (en este caso es única) y el segundo al elemento del vector p que está afectando desde 1 hasta R . Los valores así ponderados ingresan a un operador que los suma haciendo el producto escalar de una sola fila de la matriz W y el vector p , como se observa en la Fig. 3.5. A las entradas ponderadas se les suma un bias para obtener el argumento n que ingresará a la función de transferencia dando como resultado la salida a .

Si
$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b,$$

Entonces la salida a se puede describir como: $a = f(w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b)$




Fig. 3.5 Neurona con vector de entrada de múltiples valores [Demuth y Beale (2002)].

Colocando dos o más neuronas (Fig. 3.6), estas pueden combinarse en una capa, que puede estar interconectada con otras.




Fig. 3.6 Esquema de una red de neuronas de una capa [Demuth y Beale (2002)].

Sea una red con una capa de neuronas, con un vector de entrada p con R elementos y S número de neuronas. Cada elemento del vector de entrada p está conectado a cada neurona a través de una matriz de

pesos W de dimensiones $S \times R$ (Fig. 3.7). En cada neurona se produce la suma del vector de entrada ponderado más el bias que dará como resultado su propio argumento escalar n_i . Luego todos los n_i tomados de las S neuronas producen un vector n de S elementos de entrada a la función de transferencia seleccionada. Esto da como salida un vector columna denominado a , también de S elementos.

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,R} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ w_{S,1} & w_{S,2} & \cdots & w_{S,R} \end{bmatrix}$$

Fig. 3.7 Matriz de pesos que multiplica a al vector de datos p [Demuth y Beale (2002)].

Una característica a enfatizar es que los vectores de información son evaluados por todas las neuronas de manera simultánea (toda la información es compartida por todas las neuronas), este tipo de conexión se llama *conexión total* o *full connection*.

Si se extiende la multiplicación de la red colocando varias capas, cada una tendrá su matriz de pesos W , su bias b , y su vector de salida a como se muestra en la Fig. 3.8.

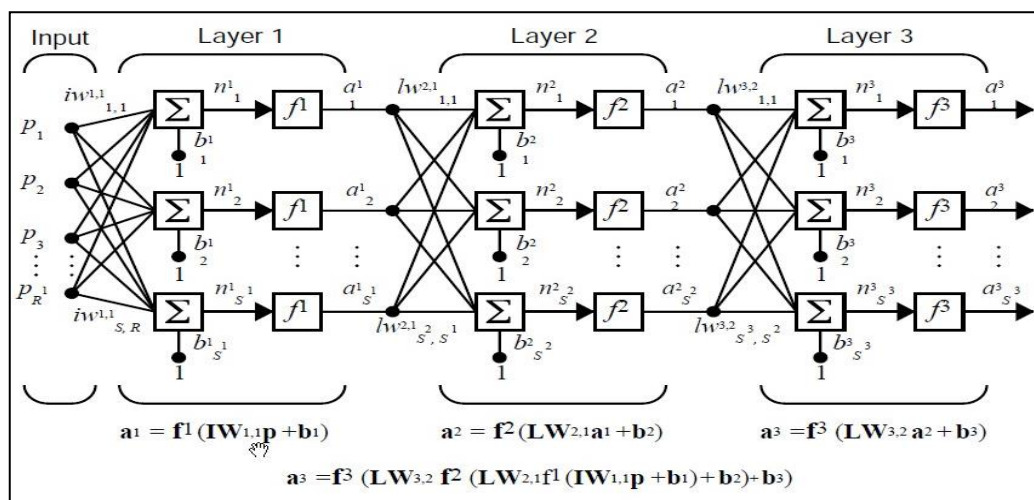


Fig. 3.8 Red Neuronal de tres capas más capa de entrada. [Demuth y Beale (2002)]

El número de capa se denota como un supra índice tanto en el número de entradas como de neuronas, así como en los pesos, los bias, los argumentos y las salidas. Diferentes capas pueden tener distinta cantidad de neuronas. En un red, la salida de cada capa intermedia es la entrada de la siguiente, por lo que cada capa j puede ser analizada como una red de una sola capa con S^{j-1} entradas, S^j neuronas y una matriz de pesos W^j de dimensiones $S^{j-1} \times S^j$. Las entradas de la capa j son los a^{j-1} y las salidas a^j .

Las capas de una red multicapa pueden cumplir diferentes funciones. La que produce la respuesta de la red se llama “*capa de salida*”, las otras se denominan *escondidas*. En el ejemplo de la Fig. 3.8 la capa 3 es la *capa de salida* y las restantes (1 y 2) son *capas escondidas*.

Estos tipos de redes son muy poderosas. Una red de dos capas con una función de transferencia sigmoidea en la primera y una lineal en la segunda puede ser entrenada para aproximar cualquier función (con un número finito de discontinuidades) dando muy buenos resultados.

Si bien existe una amplia variedad de tipos de redes neuronales y de arquitecturas, lo anteriormente mencionado abarca un esquema de cálculo general. Luego se deberá afinar el problema tomando en cuenta las variaciones particulares según el tipo de red considerado.

3.3 Acondicionamiento de los datos de entrada a la red

Para el correcto funcionamiento de la red, es importante que la información con la cual se la alimente, esté apropiadamente acondicionada. En general, la información asociada a los vectores de entrada multiparamétricos tiene diferentes escalas y unidades de medida. Por ejemplo, existen parámetros de EA que tienen escalas logarítmicas y lineales y las unidades de medida de los parámetros varían desde V, dB, hasta aJ (atto Joules), etc., esto puede afectar directamente la estabilidad del cálculo iterativo de la red acarreando como consecuencia que sea menos eficiente en el procesamiento, o que tarde mucho tiempo en converger a un resultado que quizá sea una pobre aproximación respecto al resultado deseado. También se debe tener en cuenta que no todas las funciones de transferencia pueden trabajar con cualquier valor de entrada. Es entonces que se debe realizar un escalado de las variables de manera de homogeneizar unidades y magnitudes. Aunque existe una amplia variedad de escalados, a continuación se mostrarán dos de los más utilizados, que son el *minimax* y el *autoescalado*.

3.3.1 Escalado tipo Minimax

Este escalado toma los valores de un parámetro determinado respetando sus proporciones relativas al máximo y mínimo valor del intervalo considerado, y los normaliza en el intervalo [0-1] mediante el siguiente algoritmo:

$$X_{Escalado} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (Ec. 3.1)$$

Donde X_i es un n valor del parámetro, X_{min} y X_{max} son los mínimos y máximos respectivamente de toda la lista de valores del parámetro en el intervalo considerado.

3.3.2 Escalado tipo Autoescalado.

En el autoescalado, como primer paso se calcula el valor promedio de la lista del parámetro considerado, luego a cada valor se le resta el promedio calculado quedando entonces los datos centrados en el promedio, para luego dividir cada valor por el desvío estándar de la muestra. Esto normaliza las unidades de los datos, pero en general condiciona al uso de este escalado a lotes de datos que tengan distribuciones normales.

El algoritmo de cálculo es:

$$X_{Autoescalado} = \frac{X_i - X_{med}}{\sigma} \quad (Ec. 3.2)$$

Donde nuevamente X_i es un n valor del parámetro, X_{med} es el promedio de la muestra de valores del parámetro y σ el desvío estándar.

Si bien estos procedimientos son simples no se les debe restar importancia, ya que escalados inapropiados pueden cambiar la relación interna entre las diferentes variables y alterar los resultados finales [Zupan y otros (1993)]. Por esto, antes de realizar cualquier tipo de escalado, se recomienda corroborar que las variables transformadas sigan describiendo adecuadamente el problema analizado. En la mayoría de los casos, la naturaleza del problema será lo que determine el tipo de escalado a ser utilizado.

3.4 Descripción del proceso de entrenamiento y predicción.

La etapa de entrenamiento será comenzada una vez que la red ha sido conformada y los datos de entrada ajustados apropiadamente. En esta etapa la red comienza a aprender a reconocer los datos de entrada (en el caso de clasificación) y a auto ajustarse para obtener la respuesta buscada. Este procedimiento de

aprendizaje puede ser *asistido*, donde se le da a la red las respuestas correctas y *no asistido*, donde no se le indica a la red cual es el resultado al que debe llegar.

Para comenzar el entrenamiento se debe disponer de un lote de datos para tal fin, estos tienen que ser representativos del problema y su función es únicamente la de entrenar la red para desarrollar una función deseada. Entonces, en primera instancia se trabajará tratando de optimizar las variables de la red neuronal (arquitectura, factores de corrección, cantidad de tiempo de cálculo, etc.) para que el entrenamiento produzca un valor de error que sea lo suficientemente bajo además de lograr el objetivo buscado.

Se debe tener en cuenta que el verdadero valor de error del modelo entrenado (y por lo tanto de la red) debe ser medido con respecto al lote de predicción y no al de entrenamiento, es decir que el verdadero error de la red es el que da como resultado la etapa de predicción o simulación y no la de entrenamiento.

El proceso de entrenamiento suele ser la parte más extensa en la calibración de la red. En esta etapa la red neuronal genera una matriz de pesos que iterativamente se va corrigiendo hasta lograr valores mínimos de error especificados por el usuario, y esto lo hace (en el caso de aprendizaje asistido) comparando los valores de salida de la red con respecto a los valores objetivos (respuestas correctas proporcionadas por el usuario) y corrigiendo los pesos y el bias hasta minimizar las diferencias. Este sistema generalmente se utiliza en redes de tipo retro propagación. Existen también entrenamientos no supervisados en los que la red aprende por sí sola a clasificar en grupos la información, sin haberle indicado cuales son los resultados correctos (redes de mapas auto organizados y redes competitivas). Teniendo esto en cuenta, el lote de información es pasado varias veces por la red, en donde se define como una “*época*” al pasaje completo de todos los vectores de datos de un lote por la red. Usualmente el entrenamiento conlleva una gran cantidad de épocas que según la red, o el porcentaje de error requerido y otros factores, puede variar desde unos cientos, hasta miles. Esto se relaciona directamente con el tiempo de cálculo requerido para finalizar el proceso de entrenamiento. Una categorización de los modos de ajuste del entrenamiento puede hacerse basada en la forma de actualizar los pesos y los bias. Si se actualizan cada vez que se presenta a la red un vector de entrada de información de todo el lote se denomina *modo incremental*. Si lo hacen luego de pasar todo el lote de información, es decir luego de una época se denomina *modo batch*.

Una vez que se han alcanzado los objetivos para los cuales se entrenó la red, se procede a la etapa de simulación en donde se debe evaluar su verdadera eficiencia. Para realizar esto se le presenta a la red un lote de datos nuevos para predicción, el cual procesará de manera mucho más rápida que en la etapa de entrenamiento, debido que tanto la matriz de pesos como los bias ya están calculados y no se modificarán si los resultados son satisfactorios. Luego se evalúa el error de la red en la predicción, que por lo general es mayor que el error durante el entrenamiento y si el valor obtenido es aceptable no se vuelven a modificar los pesos ni el bias (no se re-entrena a la red). Si el resultado no es satisfactorio se debe volver a entrenar la red modificando las épocas, la cantidad de datos de entrada, y otros parámetros hasta lograr el objetivo.

3.5 Descripción de reglas de aprendizaje y red elemental Perceptrón.

A continuación se analizará el funcionamiento de una red neuronal del tipo “Perceptrón” para mostrar cómo se aplican las reglas de aprendizaje y como la red toma las decisiones para un caso de clasificación. Las redes tipo *Perceptrón* son de las más antiguas. Fueron creadas por F. Rosenblatt en 1960, son muy simples y están compuestas por una sola capa de neuronas. En esta red, los pesos y el bias pueden ser entrenados para producir un vector objetivo cuando se le presenta a la entrada un determinado vector de datos. La técnica de entrenamiento usada se llama “*Regla de aprendizaje Perceptrón*”. Estas redes son muy adecuadas para la clasificación de patrones siendo muy rápidas y confiables para los problemas que pueden resolver. El conocimiento del funcionamiento de la operación del Perceptrón provee muy buenas bases para el entendimiento de redes más complejas. A continuación se muestra una red de una neurona (Fig. 3.9) que usa una función de transferencia tipo escalón, donde cada entrada externa es ponderada con un peso apropiado w_{IR} . Todas las entradas ponderadas son sumadas y a estas se les agrega el bias. Luego la resultante es enviada a la función de transferencia tipo escalón.

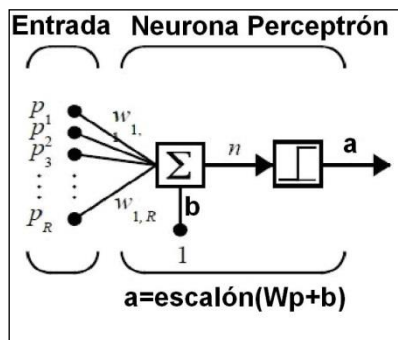


Fig. 3.9 Perceptrón con función de transferencia tipo escalón. [Demuth y Beale (2002)]

La salida de la función de transferencia escalón es 0 o 1, produciendo un 1 si la entrada *net*a a la función de transferencia es igual o mayor a 0, de lo contrario da 0 como resultado. La función escalón le da al Perceptrón la habilidad de clasificar los vectores de entrada en un espacio de dos regiones. Estas dos regiones están delimitadas por la *barrera o límite de decisión* “L”, donde $L = Wp + b = 0$, es perpendicular a la matriz de pesos W y cambia según el valor que tome el bias (Fig. 3.10). Para el caso que los vectores de entrada computen sobre y para la izquierda de la línea L resultará en una entrada *net*a mayor a cero, dando la función de transferencia un 1 como salida. Los vectores de entrada debajo y hacia la derecha de L causan que la neurona tenga un cero por salida. La línea de división L puede ser movida a cualquier región para clasificar las entradas del espacio muestral cambiando el valor de los pesos y del bias.




Fig. 3.10 Representación gráfica de las zonas de decisión del Perceptrón [Demuth y Beale (2002)].

Las neuronas con función escalón y sin el bias siempre tendrán una línea de clasificación que pivotará en el origen de coordenadas. Cuando se adiciona el bias, la neurona puede resolver problemas en los que diferentes vectores de entrada se encuentren en diferentes lados del origen de coordenadas. El bias permite entonces, que la barrera de decisión pueda moverse lejos del origen. La arquitectura de una red tipo Perceptrón consiste en una sola capa de S neuronas, conectadas a R entradas a través de un conjunto de pesos W_{ij} como muestra la Fig. 3.11.




Fig. 3.11 Red Perceptrón de 3 neuronas con función de transferencia escalón y de una sola capa [Demuth y Beale (2002)].

Las reglas de aprendizaje se definen como el procedimiento para modificar los pesos y el bias de la red neuronal (también es referido como algoritmo de entrenamiento). El aprendizaje puede ser *asistido* (o supervisado) o *no asistido* (o no supervisado).

A continuación se analiza un vector de datos de entrada asociado a los resultados de clasificación que deberían obtenerse (con un porcentaje de error) una vez que la red esté correctamente entrenada. El vector de datos ingresado a la red tiene esta conformación $\{p1, t1\}, \{p2, t2\} \dots \{pq, tq\}$, donde se le indica a la misma que pq es un dato de entrada de la red y tq es el correspondiente resultado objetivo (es decir lo que debería dar como salida la red). Por esta razón las reglas tipo Perceptrón se califican como “de aprendizaje supervisado”. A medida que la información es ingresada a la red, esta compara sus resultados con las respuestas objetivo, y las reglas de aprendizaje son usadas para modificar los pesos y el bias con el fin de acercar las salidas de la red a las respuestas objetivo. En contraste, en el *entrenamiento no supervisado*, los pesos y el bias son únicamente modificados en respuesta a los vectores de entrada, no existiendo respuestas objetivo.

El objetivo de los Perceptrones es disminuir el error e , el cual es la diferencia entre la respuesta objetivo t y la salida de la neurona a . Teniendo en cuenta lo anterior, se pueden dar tres casos para ajustar los pesos:

Caso 1: Si un vector de entrada es presentado a la red y la salida de la neurona es correcta, el vector de pesos W no es alterado. (Si $a = t$, entonces $e = t - a = 0$).

Caso 2: Si la salida de la neurona es 0, debiendo haber sido 1 (Si $a = 0$ y $t = 1$, entonces $e = t - a = 1$), el vector de entrada p es sumado al vector de pesos W acercándolo al vector p , e incrementando las posibilidades de que la próxima vez el vector de entrada sea clasificado con un 1.

Caso 3: Si la salida de la neurona fuera un 1, debiendo haber sido 0 (Si $a = 1$, y $t = 0$, entonces $e = t - a = -1$), el vector p se resta del vector de pesos W , alejándolo del vector p y aumentando las probabilidades de que p sea clasificado como 1 en el futuro.

Las reglas de aprendizaje Perceptrón en términos del error e y del cambio que debe hacerse al vector de pesos ΔW se resumen a:

Caso 1: Si $e = 0$ entonces hacer cambio $\Delta W = 0$

Caso 2: si $e = 1$, entonces hacer cambio $\Delta W = p^t$

Caso 3: si $e = -1$, entonces hacer cambio $\Delta W = -p^t$

Los tres casos pueden condensarse en una sola ecuación:

$$\Delta W = (t - a) p^t = e p^t$$

La expresión para el cambio del bias, considerando al bias como un peso que siempre tiene una entrada de 1:

$$\Delta b = (t - a) = e$$

Resumiendo entonces las reglas Perceptrón pueden ser escritas como:

$$W_{nuevos} = W_{viejos} + ep^t$$

$$b_{nuevos} = b_{viejos} + e$$

Esta forma de escritura es la base para la programación de los algoritmos de estos tipos de redes. Las reglas Perceptrón convergen a una solución en un número finito de pasos si la solución existe, pero solo pueden clasificar problemas linealmente separables. Esto es debido a su arquitectura y función de transferencia.

Otras variantes de estas redes Perceptrón con función de transferencia sigmoideal de varias capas han demostrado capacidad para clasificar condiciones de desgaste de la herramienta de corte en ensayos de torneado con diferentes materiales, geometrías y recubrimientos de herramientas. Existe una variedad de trabajos que prueban diferentes combinaciones de cantidad de neuronas y capas escondidas de procesamiento. Estas arquitecturas muestran variabilidad en el desempeño según las configuraciones de ensamble y las mismas son seleccionadas en según el arreglo que brinde el mejor resultado para identificar el estado de desgaste de las herramientas en base a la ponderación del porcentaje de error de la red. [Dimla Sr. y otros (1997), Dimla Snr. (1999)]. Las variables con las que son alimentadas las redes pueden ser las fuerzas estáticas y dinámicas de corte, así como también las aceleraciones involucradas en el proceso, además de la EA. La calidad de la información con que se alimenta la red debe ser analizada eliminando valores fuera de lo común (outliers), examinado la correlación entre las variables y además normalizando la información con el fin de no saturar la red con magnitudes muy diferentes entre los datos de entrada [Dimla Sr. y Lister (2000)]. Existen además combinaciones de redes neuronales tipo Perceptrón que cuentan con sistemas soportes de decisiones de lógica difusa aplicado a la detección de la condición de desgaste en herramientas [Balazinski y otros. (2002)], lo que indica que las variantes que pueden ser adoptadas en el campo de análisis de señales es muy amplio y se deberá observar cuales son las combinaciones que mejor se adapten al control en línea del estado de la herramienta.

A continuación se detallará otro tipo de red neuronal a la red Perceptrón, la misma fue utilizada en el presente trabajo para la tarea de clasificación de las condiciones de broca alimentándola con las señales obtenidas del ensayo.

3.6 Red neuronal tipo Mapas Topológicos Auto Organizados - Kohonen

Existen diferentes formas de evaluar un paquete de información, una forma puede ser algebraica donde se evalúan los valores numéricos, magnitudes y signos que son atributos algebraicos. Otra forma es analizar la relación “entre datos”, una manera muy gráfica de entender este concepto se muestra en la Fig. 3.12.




Fig. 3.12 Comparación de la misma serie de datos donde se observa un nuevo nivel de información al considerar la *topología* de los datos [J. Zupan y J. Gasteiger 1993].

J. Zupan y J. Gasteiger (1993) explican que de alguna manera puede verse un nivel nuevo de información evaluando la relación *entre* los números en vez de considerar solo sus valores numéricos. Cuando se focaliza entonces en la relación entre datos se está trabajando con la *topología* de la información. Esta forma de análisis asociada a una necesidad de disminuir la cantidad de variables multidimensionales (reducción dimensional) en la evaluación de una problemática determinada llevó a Teuvo Kohonen a introducir el concepto de “*Mapas Topológicos Auto Organizados*” o *SOM* (“*Self Organized Maps*”) que son redes neuronales que dan como resultado mapas que representan la relación entre datos, modelando la superficie multidimensional y colocando la información en una superficie de dos dimensiones (mapas).

Este tipo de red fue utilizada con éxito en diferentes aplicaciones como ser la detección de fisuras en fabricación de mosaicos [Barrera y otros (2005)], clasificación de origen de aceites de oliva y medición de la reactividad de enlaces químicos [Zupan y otros (1993)], mejora de las características de las señales (relación señal ruido) de la EA en el control de desgaste de herramientas de micro maquinado [Chen y otros (2013)], análisis de modos de falla en materiales compuestos [Godin y otros (2005)], tratamiento de imágenes y señales en general dentro de otras variadas aplicaciones [Kohonen (2001)].

La arquitectura de la red neuronal tipo SOM se caracteriza por su distribución espacial tipo grilla o red formada por las neuronas que componen la red. Estas pueden organizarse con variadas formas, por ej.: rectangular, hexagonal, o de manera aleatoria como se muestra en la Fig. 3.13.




Fig. 3.13 Disposición de neuronas en una SOM. **a.** Red rectangular **b.** Red hexagonal **c.** Red aleatoria. [Demuth and Beale (2002)].

Esta variación de los arreglos conlleva a que a cada neurona se asocie con una cantidad de “*neuronas vecinas*”, definiéndose grupos de *vecindades* con los diferentes tipos de geometría según algún criterio seleccionado. El concepto de “*vecindades*” es clave para comprender el comportamiento de estas redes y su poder para reconocer patrones entre los datos así como su capacidad de organizarse topológicamente. Los diferentes arreglos geométricos de las redes varían en el número de vecinos y en la forma del aglomeración de las neuronas. En la Fig. 3.14 a se pueden observar dos vecindades de diferente tamaño de geometría circunferencial y en la Fig. 3.14 b vecindades de geometría rectangular donde se detallan tres niveles diferentes de proximidad. Esto puede extenderse a otras geometrías de redes (hexagonales, aleatorias, etc.).

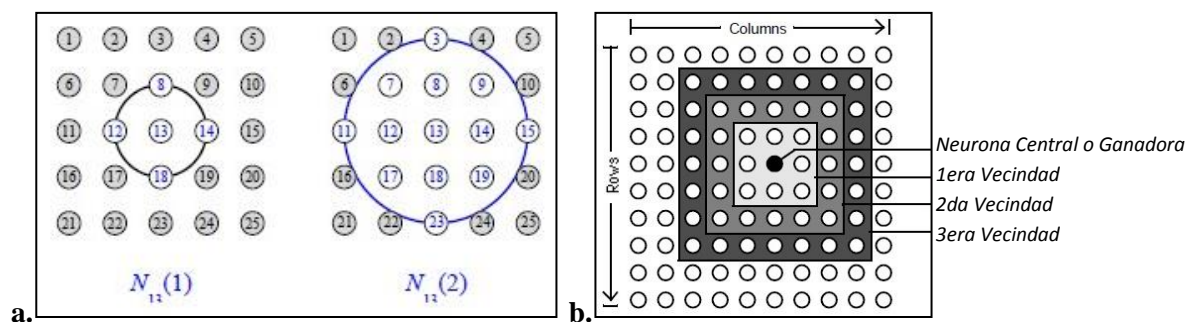


Fig. 3.14 Red rectangular con vecindades. **a.** Circunferenciales **b.** Rectangulares [Demuth y Beale (2002)].

En general para evaluaciones visuales de los resultados (mapas) las redes hexagonales son preferidas ya que no favorecen la corrección vertical y horizontal como lo hace la rectangular [Kohonen(2001)]. También se puede variar el espacio sobre el cual son representadas las neuronas, ya que si la superficie (red de neuronas en 2D) se curva a manera de toroide, se puede recorrer esta figura sin encontrar límites geométricos mapeando la superficie de manera infinita. Para esto, se conectan los índices de los extremos del mapa en el algoritmo de la red. Luego para mostrar los resultados el toroide se desdobra y se muestra la información de manera extendida en un plano de dos dimensiones. En la Fig. 3.15 se puede observar la correspondencia posicional de la información y los sucesivos pasos para transformar una red planar en un toroide uniendo alternativamente sus extremos.




Fig. 3.15 Modificación de una distribución planar de neuronas a una toroidal [J. Zupan y J. Gasteiger (1993)].

Las redes SOM son de una sola capa y el tipo de aprendizaje es competitivo no supervisado. Esta red no recibe la relación entre los objetos de entrada y la respuesta objetivo, sino que sola encontrará las asociaciones entre los vectores de entrada. En el aprendizaje competitivo todas las neuronas de la red producen un resultado al ingresar un vector de datos, pero solo el ganador (neurona ganadora), será la respuesta única de la red que se registrará en el mapa, mientras que las respuestas no ganadoras se harán cero. Luego, a las neuronas vecinas a la ganadora se les aplica una corrección de pesos y una modificación del bias según ciertas reglas. Esto permitirá mapear la estructura de la información asociando los vectores de información que sean semejantes. Las neuronas entrenadas con reglas de aprendizaje tipo Kohonen se ajustan gráficamente para representar en un mapa de dos dimensiones las entradas de las señales a la red que son similares entre sí.

Para comprender el funcionamiento de una red tipo SOM se comenzará por explicar un ejemplo extraído del tutorial de MATLAB para redes neuronales donde se detalla el funcionamiento de una neurona de tipo competitivo. Luego este comportamiento podrá ser extrapolado a una red de neuronas más complejas.

En la Fig. 3.15 se puede observar la arquitectura de una neurona tipo competitiva donde hay un operador denominado $ndist$ que recibe el vector de datos p y una matriz de pesos $IW^{l,l}$ cargada con anterioridad. Este operador da como salida un vector de S^l elementos (el supra índice indica la capa de pertenencia). Estos elementos se definen como los negativos de la distancia entre el vector de entrada p y los vectores de las filas de la matriz de pesos $iW^{l,l}$. La matriz de pesos IW es una matriz que se utiliza desde el inicio del ciclo de cálculo, en principio los pesos de esta matriz pueden tener cualquier valor (generalmente normalizados) y están distribuidos al azar. Estos pesos luego se ajustarán a medida que progrese el cálculo iterativo.




Fig. 3.15. Arquitectura de una neurona competitiva [Demuth and Beale (2002)].

La entrada neta n^l de una capa competitiva se calcula buscando el negativo de la distancia entre los vectores de entrada p y los pesos $iW^{l,l}$ para luego sumarles el bias. Si todos los bias son 0, el máximo valor de entrada que la neurona puede tener es 0, esto ocurre cuando el vector de entrada es igual al vector de pesos de una neurona determinada. La función de transferencia competitiva (C) acepta las entradas n (vector p evaluados en $ndist$ con respecto a los pesos w más el bias) y da como salida 0 para todas las neuronas excepto para la ganadora, que en este caso es la neurona asociada al valor más positivo de las entradas n , y hace esta salida igual a 1. Resumiendo, si todos los bias son 0, entonces la neurona cuyo vector de pesos está más cerca del vector de entrada p tiene el valor menos negativo y dará el valor n más grande, razón por la cual gana la competencia y esta salida toma valor 1, haciendo 0 el resto de las demás neuronas.

El algoritmo competitivo permite que los pesos de las neuronas aprendan los vectores de entrada. En consecuencia la neurona cuyo peso esté más cerca del vector de entrada p es actualizada para estar aún más cerca. El resultado de este mecanismo realizado de manera iterativa es que la neurona ganadora es más propensa a ganar la competencia nuevamente cuando ingrese un vector de similares características, y menos propensa a ganar cuando un vector de entrada de diferentes características sea ingresado al sistema. A medida que más vectores son pasados por la red, cada neurona ajusta su distancia a un grupo de vectores de entrada con alguna similitud. Eventualmente si existen suficientes neuronas, cada grupo de vectores de datos similares tendrán una neurona que tenga salida 1 cuando el vector de ese grupo sea presentado y tendrá salida 0 el resto del tiempo. Este comportamiento se ve incrementado aún más por la aplicación de funciones que además de corregir los pesos de las neuronas ganadoras modifican los pesos de las vecindades asociadas a esas neuronas haciendo que las mismas se aglutinen formando clústeres de neuronas, esto da como resultado zonas de clasificación de información.

Los criterios para seleccionar la neurona ganadora pueden variar, en un caso puede ser la neurona que tenga el valor de salida más alto en toda la red o la que tenga el peso (W) más parecido a la señal de entrada como el caso del ejemplo anterior. Una vez seleccionada la neurona ganadora (C) según el criterio deseado se deben corregir los pesos de esta neurona en cuestión y de la vecindad también, de manera que su próxima respuesta sea mayor o más cercana al comportamiento seleccionado. Las correcciones que se realizan en la vecindad no son iguales para todas las neuronas sino que dependen de la *distancia topológica* $dc-dj$ de una neurona cualquiera de la vecindad J con respecto a la neurona ganadora C .

$$a(.) = a(dc - dj) \quad (Ec. 3.3)$$

La extensión y la forma de la estimulación de la corrección hacia las vecindades depende de la función $a(.)$. La Fig. 3.15 muestra las diferentes formas que puede tener dicha función de corrección.




Fig. 3.15 Forma de las funciones de corrección en respecto de la vecindad **a.** constante, **b.** triangular, **c.** Gaussiana [Modificado de J. Zupan y J. Gasteiger (1993)].

Estas correcciones además de decrecer con el aumento de la distancia $(d_c - d_j)$, decrecen a medida que aumentan los pasos de la iteración para hacer un ajuste más fino antes de finalizar el entrenamiento. Esto se lleva a cabo multiplicando la Ec. 3.1 por otra función $\eta(t)$ monótonamente decreciente, por lo que la nueva función queda determinada de la siguiente manera:

$$f = \eta(t) \cdot a \cdot (d_c - d_j)$$

A su vez $\eta(t)$ se puede expresar como:

$$\eta(t) = (a_{\max} - a_{\min}) \left(\frac{t_{\max} - t}{t_{\max} - 1} \right) + a_{\min}$$

Donde t es el número de vectores de información (1, 2, 3, ..., n) que van ingresando a la red en el proceso de entrenamiento y t_{\max} es el número total de vectores del lote de datos que serán ingresados durante el entrenamiento. Por lo tanto el tiempo de entrenamiento será proporcional al número de objetos ingresados a la red. Cuanto más grande sea el lote de entrenamiento, mayor será la duración de dicha etapa. Las correcciones pueden ser limitadas tanto en sus valores mínimos como máximos. Esto previene que sean tan pequeñas que la red no converja a un resultado con un error bajo, en una cantidad razonable de épocas. Por otro lado, si son valores altos, se puede acortar el tiempo de entrenamiento siempre y cuando la red mantenga la estabilidad. Podría ocurrir que dada la severidad de la corrección la red comience a oscilar frustrando la convergencia al mínimo error independientemente de la cantidad de épocas que se procese la información.

La ecuación de corrección de pesos de las neuronas de la vecindad definida por la función f depende de criterios competitivos mediante los cuales se seleccionó la neurona ganadora C . La ecuación correspondiente al criterio de selección donde gana la neurona que tenga el peso más similar al vector de entrada se puede escribir como:

$$W_{ij}^{nuevo} = W_{ij}^{viejo} + \eta(t) \cdot a \cdot (d_c - d_j) \cdot (p_i - W_{ij}^{viejo}) \quad (\text{Ec. 3.4})$$

Donde p_i es un vector de datos arbitrario de la matriz de entrenamiento. La función depende de $\eta(t)$, donde t está asociado al número de épocas por la cual la red está iterando.

La distribución inicial de los peso (antes de comenzar el entrenamiento) asociados a las neuronas puede ser de manera lineal o aleatoria donde a la larga está demostrado que los pesos aleatoriamente ordenados, se ordenaran usualmente en las primeras cien iteraciones [Kohonen (2001)]

Una de las utilizaciones que se le puede dar al bias en este tipo de redes es debido a la existencia de algunas neuronas que nunca llegan a ser ganadoras. Debido a esto, sus pesos nunca son ajustados, y por el contrario sus pesos quedarán desactualizados y lejos de los vectores de entrada, sin importar cuánto se entrene la red. Estas neuronas son llamadas neuronas muertas y no realizan ninguna función útil. Para prevenir este suceso, el bias es usado para darle solamente a las neuronas que raramente o nunca ganan la competencia una ventaja sobre las neuronas que ganan más frecuentemente. Un bias positivo sumado a la distancia negativa (como el caso de la Fig. 3.14) hace que una neurona lejana tenga más probabilidades de ganar. Para hacer esto, un promedio de las neurona activas es registrado. Este valor promedio es usado

para actualizar el bias de las neuronas raramente activadas haciéndose cada vez más grande y reduciéndose progresivamente para las neuronas que ganan frecuentemente. Como resultado el bias de la neurona “poco ganadora” es aumentado, incrementando la respuesta de esta neurona con respecto a los vectores de entrada y así actualizando sus pesos, eventualmente esta neurona responderá en promedio igualmente a los vectores de entrada como lo hacen las otras neuronas. Este procedimiento tiene dos efectos beneficiosos. El primero es que para una neurona que nunca gana la competencia por tener sus pesos lejos de los vectores de entrada, su bias se hará lo suficientemente grande como para que le sea posible ganar la competencia, y cuando esto suceda, la neurona se moverá hacia un grupo de vectores de entrada de manera de seguir disminuyendo el espacio que los separa y entonces su bias comenzara a disminuir hasta 0. Así es resuelto el problema de las neuronas muertas. La segunda ventaja del bias es que fuerza a cada neurona a clasificar aproximadamente el mismo porcentaje de vectores de entrada, por lo tanto si existe una gran cantidad de vectores de entrada de una especie, esta zona atraerá más cantidad de neuronas y podrá clasificar la información en subclases más pequeñas.

Finalmente, los mapas que dan como resultados las SOM pueden ser mostrados de diferente manera. Algunas de ellas pueden físicamente cambiar la distancia de las neuronas de la red para aglutinarse mostrando los grupos de neuronas que tienen respuestas similares como se muestra en la Fig. 3.16 a o pueden ajustar simplemente sus pesos en posiciones fijas mostrando regiones que clasifican vectores datos que tienen características semejantes. En la Fig. 3.16 b se pueden apreciar zonas de clasificación identificadas con diferentes colores en donde se pueden diferenciar cinco regiones topológicas dentro del mapa.

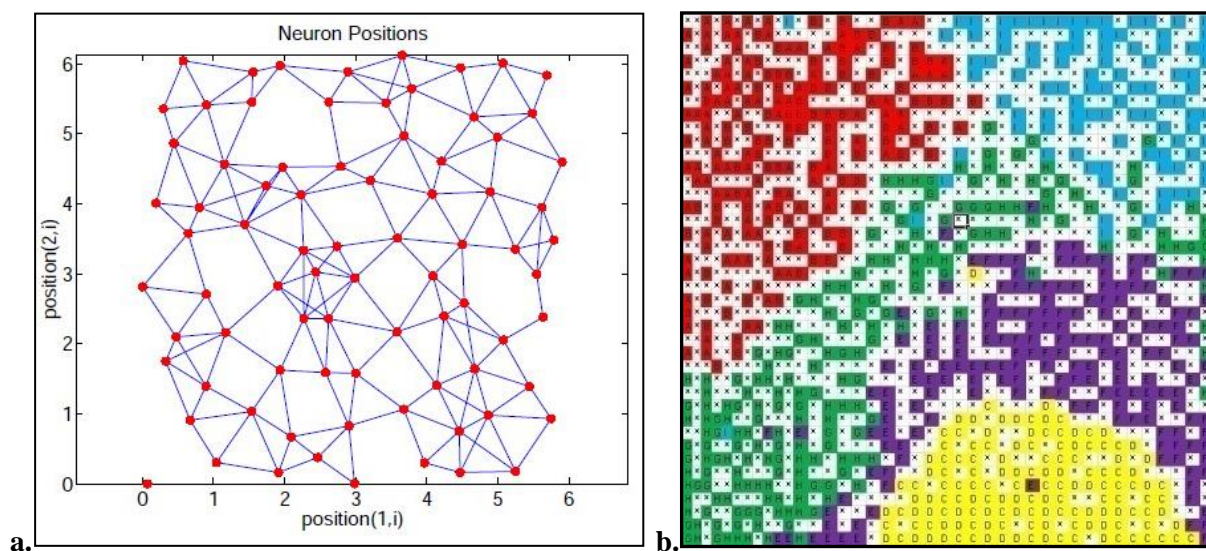


Fig. 3.16 Diferentes mapas resultantes de redes SOM. **a.** Neuronas móviles [Demuth y Beale (2002)]. **b.** Neuronas fijas con zonas de clasificación.

Como se puede observar, estos tipos de redes neuronales tienen la capacidad de resolver una gran cantidad de problemas, lineales y no lineales, y lo que es igualmente importante es que poseen la capacidad de mostrar la relación entre la información de carácter multivariable de manera sencilla.

Capítulo 4

METODOLOGÍA EXPERIMENTAL

En el presente capítulo se detallan las condiciones en que fueron llevados a cabo los experimentos, sus partes constitutivas, y configuraciones. Además se exponen los procedimientos bajo los cuales se desarrollaron los ensayos y el tratamiento de la información recolectada luego del taladrado. Los ensayos se efectuaron con cinco brocas helicoidales con distintas condiciones en sus filos. A cuatro de ellas se les efectuaron diferentes tipos de desgaste en las superficies de corte, y la restante se mantuvo en su estado original representando la condición de broca nueva. Luego, se taladraron probetas de acero, todas de iguales características, haciendo un agujero en cada una. Simultáneamente se adquirieron las señales de EA emitidas durante el proceso de corte y la fuerza de avance (FA). Para esta última fue necesario construir un soporte especial, que pudiera alojar una celda de carga, transmitiéndole la fuerza de avance y a la vez compensando la componente de torque. Una vez adquirida la información se procedió a su análisis mediante la utilización de estadística, correlación lineal, análisis por componentes principales y redes neuronales con el fin identificar las condiciones del estado del filo de las brocas.

4.1 Preparación del experimento

4.1.1. Brocas de taladrado

Las brocas utilizadas en este trabajo son de acero rápido (HSS) de geometría normalizada (DIN 1412) con un ángulo de punta de 118 grados (Fig. 4.1) y tienen un diámetro nominal de 5 mm. Su elección se debe a que se buscó reproducir un caso representativo del taladrado típico en talleres de mecanizado. Respecto a las características de las brocas, en la Fig. 4.2 se puede observar el espectro EDAX del material de una de estas donde se pueden encontrar elementos como el tungsteno, vanadio y cromo que mejoran las propiedades mecánicas, y azufre el cual es intencionalmente agregado para facilitar el afilado de la herramienta.




Fig. 4.1 Diagrama de broca normalizada con ángulo de punta de 118 grados.




Fig. 4.2 Diagrama EDAX de una de las brocas utilizada [Gómez (2012)]

Cada una de las 5 brocas utilizadas en los ensayos presenta diferencias en la condición de los filos. A continuación se resumen los distintos casos:

Broca nueva (N): Esta broca se encuentra en estado “Nueva”, es decir con sus superficies de corte afiladas y en óptimas condiciones para su uso (Fig. 4.3). La misma es utilizada como patrón de referencia para caracterizar el mejor estado de la herramienta, ya que proporciona las mejores condiciones de corte.




Fig. 4.3 Filos de la broca en estado “Nuevas” (N). **a.** 50 x. **b.** 100 x

Broca con Cráter Mecánico (CM): Esta herramienta sufrió un principio de deterioro producto taladrar un metal con alta cantidad de inclusiones y luego fue sometida a repetidos procesos de taladrado en condiciones normales de uso lo que extendió su zona de desgaste (Fig. 4.4). Esta broca sufrió craterización en la cara de ataque, eliminación parcial de borde de corte y desgaste de flanco.




Fig. 4.4 Filos de broca con Cráter Mecánico (CM) **a.** 50 x **b.** 100 x

Broca con Cráter por electro Erosión (CE): En una broca de condición nueva se efectuó la craterización en las caras de ataque, desgaste de los flancos y eliminación parcial de los filos de corte mediante electroerosión (Fig. 4.5). Este método proporciona alta precisión, repetitividad y un ajustado control del desgaste simulado sobre la herramienta. En el posicionamiento de la broca se buscó colocar el filo de manera perpendicular a la mesa de soporte, razón por la cual se coloca a la misma en un ángulo de 30 ± 2 grados. Una vez así posicionada se aproximó el electrodo (hilo de cobre de 1.5 mm de diámetro) hasta hacer contacto con el filo de la broca. Este filo tiene una longitud aproximada de 2.5 mm y el centro del electrodo fue colocado a 0.95 ± 0.02 mm de la esquina exterior del filo de la broca. La potencia de la máquina se fijó en 3.3 A y el tiempo del pulso se fijó en 2 microsegundos. El tiempo total de electro erosión fue de 60 segundos.




Fig. 4.5 Filos de broca con Cráter por Electroerosión (CE) *a.* 50 x. *b.* 100 x.

Broca con filo Achaflanado (BA): Esta broca sufrió una eliminación total del borde de corte mediante la creación de un plano o chaflán por electroerosión perpendicular a la bisectriz del ángulo del filo Fig. 4.6. La misma se colocó con una inclinación de 30 ± 2 grados respecto la normal de la mesa de fijación y con un electrodo cilíndrico de aproximadamente 60 mm de diámetro se procedió a erosionar el filo con los mismos parámetros potencia que en el caso anterior, pero con un tiempo total de operación de 90 segundos.




Fig. 4.6 Filos de broca achaflanados mediante electroerosión (BA) *a.* 50 x. *b.* 100 x

Broca con Esquina exterior Gastada (EG): Para esta condición particular de desgaste se procedió a realizar un deterioro de manera manual con una piedra de desbaste fino de las esquinas exteriores de la broca Fig. 4.7.




Fig. 4.7 Filos de broca con esquina Exterior Gastada (EG). *a.* 50 x. *b.* 100 x

A manera de resumen en la Tabla 4.1 figuran las nomenclaturas abreviadas que se utilizarán en el resto del trabajo para identificar las brocas con sus característicos filos. También se detalla la cantidad de ensayos realizados para cada condición de filo de broca.

Tabla. 4.1 Detalle de la nomenclatura y la cantidad de ensayos por condición de broca.

<i>CONDICIONES EXPERIMENTALES DE BROCA</i>		<i>CANTIDAD DE ENSAYOS</i>
Brocas en estado nuevas	<i>N</i>	4
Brocas con cráter mecánico	<i>CM</i>	7
Brocas con cráter por electroerosión	<i>CE</i>	7
Brocas con filo achaflanado	<i>BA</i>	3
Brocas con esquina gastada	<i>EG</i>	5
TOTAL		26

4.1.2 Probetas Hexagonales de acero

Las probetas utilizadas fueron construidas a partir de una barra hexagonal de acero SAE 1040 trefilada (Fig. 4.8). Esto brinda la posibilidad de minimizar las variaciones que se podrían encontrar debido a la utilización de diferentes lotes de material. Inicialmente a cada probeta se le imprimió un código de identificación y se le efectuó un Agujero Guía (AG) en el centro de la misma, con el fin de facilitar el centrado de la broca en el inicio y de eliminar el efecto de cincelado durante el taladrado. El diámetro del AG es levemente mayor al tamaño del filo central de las brocas utilizadas. El AG permite un proceso de corte más estable, con menor variación obteniéndose una mayor precisión en el taladrado.

Las características geométricas y composición química de las probetas se detallan en la Tabla 4.2.

Tabla 4.2 Detalle de las características de las probetas utilizadas.

CARACTERÍSTICAS DE LAS PROBETAS	
Longitud de probeta	95 mm \pm 0.05 mm
Distancia entre caras	14,30 \pm 0.03 mm
Agujero guía	1,5 \pm 0.02 mm de diámetro
	10 \pm 0.5 mm de profundidad
Composición Química	%W: C:0,4, Mn:0,72, Si:0,29, P:0.011, S:0,012



Fig. 4.8 Fotografía de probeta exponiendo el Agujero Guía.

Para evaluar la homogeneidad del material de ensayo se prepararon 3 lotes de material. Cada lote está compuesto por 10 probetas y se extrajo un testigo al cual se le realizaron diferentes ensayos metalográficos, evaluándose el tamaño de grano, la distribución de inclusiones, la dureza y la micro dureza en sentido paralelo y perpendicular a la dirección de trefilado. Los resultados se encuentran resumidos en la Tabla 4.3 donde se tomaron tres valores de dureza por cada testigo, luego se promediaron dando como resultado un único valor más representativo de la muestra. En las Fig. 4.9 a, b, c y d, se puede observar una comparación micro estructural entre dos testigos de diferentes lotes, extraídos a su vez, en diferentes sentidos de respecto del trefilado (paralelo y perpendicular). En estas se observa una estructura orientada de manera homogénea y muy similar entre los diferentes lotes de

material. El análisis micrográfico realizado no revela variaciones significativas de los parámetros estudiados. Lo que ayuda a maximizar las condiciones para obtener repetitividad en los ensayos y la consecuente eliminación de señales espurias de EA producidas por variación de las propiedades microestructurales dentro de la probeta.

Tabla 4.3 Detalle de las características medidas y sus resultados.

<i>CONTROL METALOGRAFICO DE LOS TESTIGOS.</i>	
Tamaño de grano (ASTM E112)	7-8
Inspección de inclusiones	Muy pocas, homogéneamente distribuidas.
Microdureza promedio en sección transversal de probeta	298,6 +/- 11 HV Perpendicular al sentido de laminación
Microdureza promedio en sección longitudinal de probeta	282,4 +/- 18 HV Paralelo al sentido de laminación
Dureza Brinnell promedio	58,6 +/- 1,95 HB
Bolilla de 2,5 mm y 187,5 Kg de carga	Perpendicular al sentido de laminación




Fig. 4.9 Testigo de lote 1, **a.** Perpendicular, **b.** Paralelo al sentido de trefilado. Testigo de lote 3, **c.** perpendicular, **d.** Paralelo al sentido de trefilado.

4.1.3 *Dispositivo para medición de Fuerza de Avance (FA) y soporte de probeta*

Para la medición de la fuerza de avance durante el taladrado se diseñó y construyó un dispositivo que debía reunir las siguientes características:

- I. Soportar la probeta firmemente durante el ensayo y a su vez proveer firme sujeción de este dispositivo sobre la mesa móvil de la máquina taladradora.
- II. Permitir un fácil cambio de probeta luego de cada ensayo.
- III. Contener una celda de carga correctamente alineada en su interior que registre la FA efectuada durante el taladrado, con muy poca pérdida, y eliminando la componente de torque (TQ).

Un detalle de los planos constructivos del soporte se encuentra en el Apéndice A2.

La probeta se halla sujeta a una morsa que se centra utilizando las caras planas del hexágono. A su vez, la morsa se posiciona sobre una platina deslizante que descansa sobre la celda de carga. Dicho conjunto está montado sobre la mesa móvil mediante garras de sujeción, lo que permite un óptimo posicionamiento de todo el equipo con respecto a la broca de taladrado acoplada sobre la máquina. En la Fig. 4.10 se puede observar el sistema en detalle.

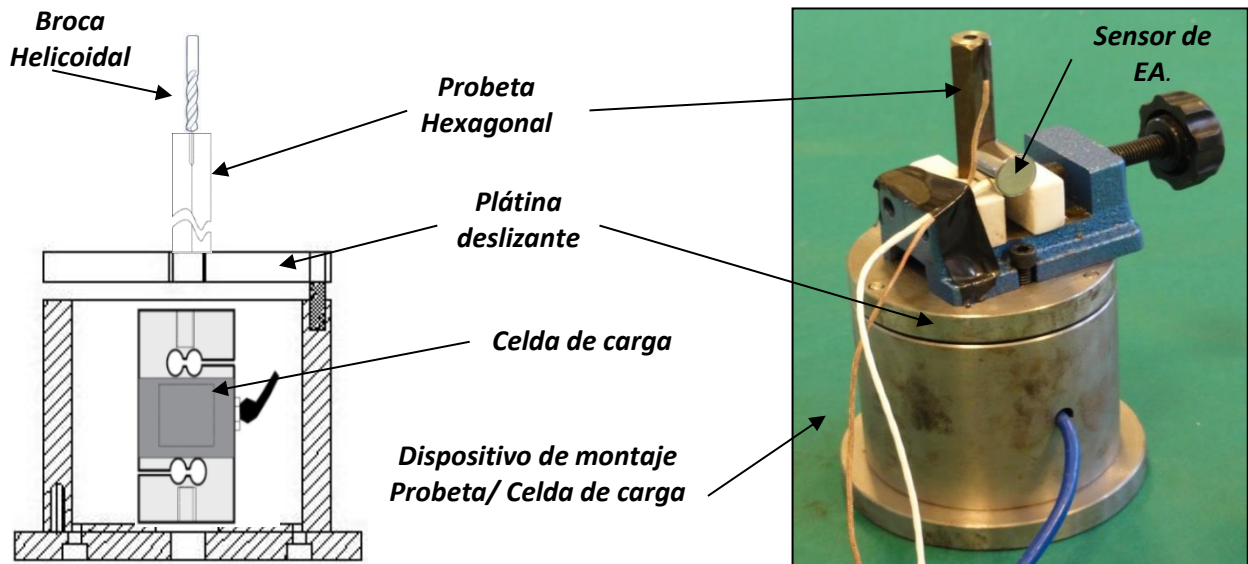


Fig. 4.10. Diagrama y fotografía del dispositivo construido para medir la FA y soportar la probeta.

En el dispositivo se utilizó una celda de carga tipo S, marca FLEXAR (fabricación nacional), modelo CZA-200 con una capacidad de 200 kg de carga y una sensibilidad de $3 \pm 10\%$ mV/V.

El sensor de EA se fija en una de las facetas laterales de la probeta, a una altura aproximada de 40 mm con respecto al borde superior. Entre ambos se coloca un acoplante acústico para evitar saltos abruptos en la impedancia (acústica). La distancia del sensor al extremo de la probeta se ha maximizado debido a que algunos procesos de taladrado con brocas defectuosas pueden alcanzar temperaturas en la zona de corte que podrían eventualmente dañar el sensor piezoeléctrico por sobrepasarse la temperatura de Curie.

4.1.4 *Máquina de taladrado*

Los ensayos se realizaron en una máquina fresadora vertical automática marca FIRST modelo LC 50 RC. Esta fresadora permite regular la velocidad de rotación del husillo y la velocidad de avance en modo automático. El avance está mecánicamente ligado a la velocidad de giro de husillo.

Para todos los ensayos se fijaron iguales condiciones de velocidad de giro de husillo y de avance.

Velocidad de giro husillo (V_{rot}) = 530 +/- 8 RPM.

Velocidad de avance (V_{av}) = 0.353 +/- 0.005 mm/s.

Esta máquina cuenta con un circuito de lubricación forzada de aceite emulsionable. Este fue utilizado en todos los ensayos con una reducción calibrada que permitía posicionar la punta del pico del circuito de lubricación de manera muy precisa cerca de la probeta.

4.1.5 Sistema de EA

El sistema de emisión acústica utilizado está compuesto por un equipo integrado en una placa PCI instalada en una computadora tipo PC de escritorio. El equipo es marca PAC, modelo PCI-2, de dos canales. Cada canal se conecta al sensor de EA a través de un conector BNC que cumple las funciones de recibir la señal del sensor piezoeléctrico y de proveer una tensión de +28 Volts para alimentar al preamplificador. El equipo de EA tiene una resolución en amplitud de 18 bits y la capacidad de adquirir, digitalizar, parametrizar y almacenar la información de EA, además de un parámetro externo. Una descripción de los bloques o unidades de procesamiento de la placa se muestra en la Fig.4.11. En este trabajo, se midió la fuerza de avance registrando la salida de voltaje de la celda de carga previamente descrita. El sensor de banda ancha utilizado es marca PAC. El preamplificador de banda ancha de 40 dB, es marca CISE. La tasa de muestreo en la utilización fue de 5 millones de muestras ("samples") por segundo (Ms/s), siendo la longitud de cada forma de onda digitalizada de 15360 puntos o 15 kilomuestras (según el ajuste del equipo) lo cual corresponde a un lapso de 3 ms de señal.

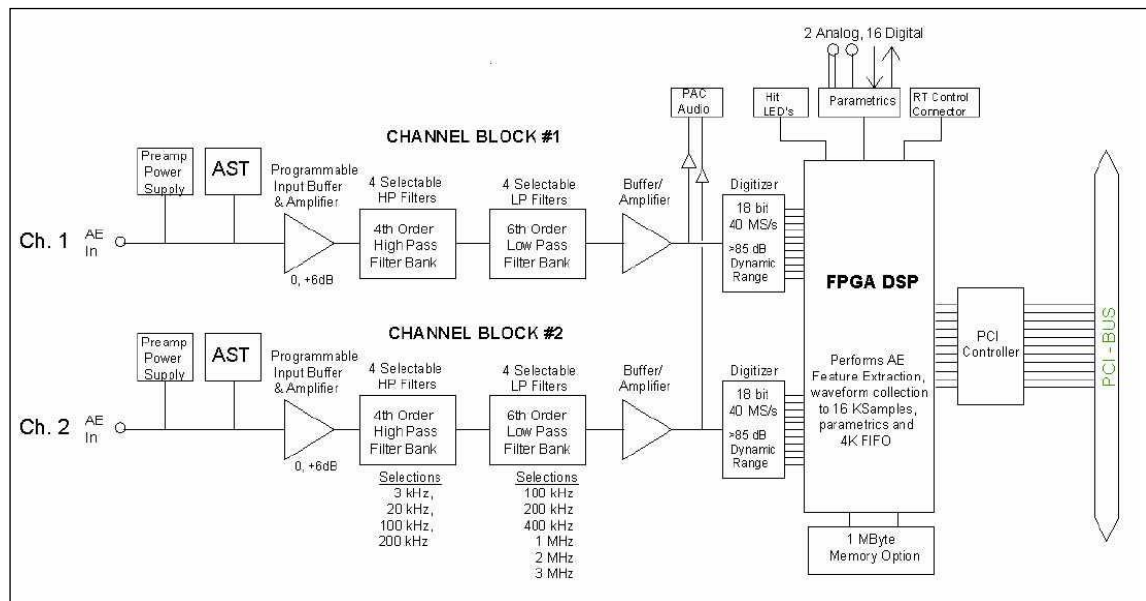


Fig.4.11 Diagrama en bloques de los pasos de procesamiento de la placa de EA. (Manual PAC 2008)

El umbral de detección de EA se estableció para todos los casos de estudio en 27 dB_{EA}. Para cada ensayo se corroboró que el equipo de EA no era disparado por ruido mecánico ni electromagnético. Los parámetros de EA elegidos para ser medidos por el parametrizador fueron: número de cuentas, Energía MARSE, Duración, Amplitud, Frecuencia Media, RMS, Energía Absoluta y Potencia Media. Algunos de estos parámetros se definen para señales tipo explosión, pero al combinarlas correctamente entre sí pueden utilizarse para señales continuas como las generadas durante el corte. Como por ejemplo la Potencia Media es calculada como el cociente entre la energía MARSE y la duración. En la adquisición de datos se agregó como parámetro externo a la FA registrada mediante la celda de carga, la cual fue conectada al equipo de EA. Para cada ensayo se verificó el correcto funcionamiento de

cada canal de EA mediante un método de simulación mecánica de señales de EA denominado “Hsu-Nielsen”. Este método está detallado en la norma IRAM MERCOSUR NM 302 y sirve para comprobar la correcta adhesión del sensor a la probeta y controlar que el equipo de EA en su conjunto funcione correctamente a partir de una señal conocida. En la Fig. 4.12 se muestra el esquema general de pasos correspondiente a un ensayo.

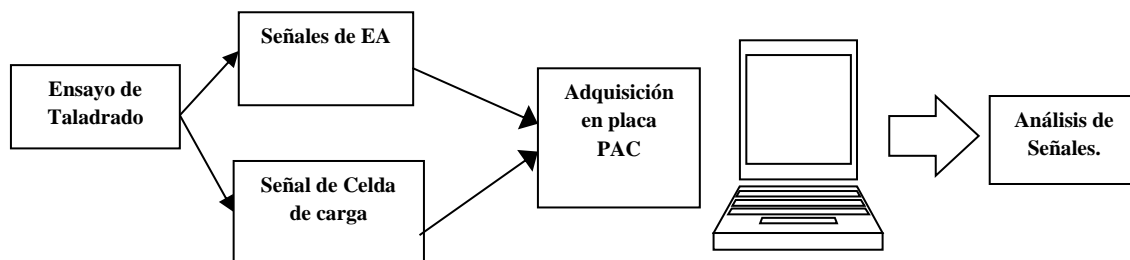


Fig. 4.12. Esquema general de secuencia del ensayo.

4.2 Descripción del ensayo

A continuación se especifica la secuencia en la que se desarrollaron las experiencias

1. Se monta el dispositivo de medición de FA y el soporte de la probeta sobre la mesa móvil (Fig. 4.13)
2. Se coloca la probeta firmemente sujeta por la morsa.
3. Se centra el husillo respecto de la probeta utilizando una broca guía de 1.5 mm de diámetro.
4. Se coloca la broca de estudio con la condición seleccionada.
5. Se instala sobre la probeta el sensor de EA utilizando gel ultrasónico como acoplante, y cinta plástica para adherirlo.
6. Se coloca una protección plástica para evitar que el fluido refrigerante haga contacto con el sensor de EA y la celda de carga.
7. Se regula la profundidad de penetración de la broca en 20 mm y las velocidades de giro y avance de husillo a los valores definidos anteriormente, colocando la máquina en modo de operación automático.
8. Se activa la adquisición del sistema de EA y se realiza una prueba manual de carga para evaluar la respuesta de la celda de carga, luego mediante el método Hsu-Nielsen se evalúa la respuesta del sistema de EA.
9. Luego de comprobar que todos los sistemas funcionan correctamente se enciende la máquina fresadora, se comienza la grabación de video y se activa la lubricación forzada, acoplando seguidamente el avance automático, dando así comienzo al ensayo.
10. Una vez que el recorrido de la broca llega a los 20 mm de profundidad el husillo se retira de forma automática. Paso siguiente, se detienen la máquina taladradora, la adquisición de la EA y la grabación en video.
11. Se desmonta la probeta, retirando el sensor. Paralelamente se toman y catalogan muestras de material taladrado (virutas).
12. Se descarga la información de la PC para su análisis.

Al iniciar el ensayo, una vez que la broca comienza a descender, lo primero que hace contacto con la probeta son los filos laterales de corte, mientras el filo central (o cincel) gira libre dentro del AG, taladrado previamente. En un primer momento, el contacto entre los filos de corte y la probeta es

intermitente y con resbalamiento, pero instantes después, la broca se centra respecto al AG y comienza propiamente el corte estable sin acción de cincelado. El corte en esta etapa se prolonga hasta que la broca penetra una profundidad de 10 mm, luego del cual finaliza el AG, y allí comienza el proceso de taladrado con cincelado, además del corte con los filos principales de la broca. En estas condiciones el taladrado se desarrolla sumando otros 10 mm de profundidad hasta que automáticamente el husillo se retrotrae una vez alcanzada la distancia total de 20 mm desde el punto de inicio, finalizando así el ensayo. Un detalle de las partes de la máquina y montaje de los ensayos se observa en la Fig. 4.13. En total se realizaron 26 ensayos (Tabla 4.1) con una duración aproximada de 40 segundos cada uno, tomándose unas 2000 muestras de parámetros (2000 hits de EA) por ensayo.



Fig. 4.13 Detalle de las partes del montaje experimental sobre maquina taladradora.

4.3 Metodología para el análisis de los datos

La información almacenada en el equipo de EA es descargada en formato “.txt” y exportada a diferentes formatos para su ajuste y posterior análisis. En la presente sección se explica el tratamiento de los datos adquiridos durante la experimentación. Esto comprende la forma en que fueron seleccionados los datos, la identificación de las variables más relevantes, y un detalle de las técnicas de análisis aplicadas para reconocer patrones, que en este caso corresponden a las diferentes condiciones de deterioro de los filos de las brocas. La cantidad de información registrada en cada ensayo es extensa. Esta debe ser seleccionada de manera que sea representativa del fenómeno que se desea evaluar. Por lo tanto primeramente se debe seleccionar la información perteneciente a los tramos del proceso, con y sin AG. También se considera la importancia relativa de cada parámetro, de manera de trabajar con los más representativos del proceso. Además se debe expresar esta información de manera que permita develar las relaciones entre las

variables y las condiciones de los filos de corte de las brocas. Las formas de análisis seleccionadas se basaron en dos conceptos. El primero es de tipo estadístico y comprende una serie de análisis donde se evalúa la distribución de los diferentes parámetros de EA y FA y la correlación entre los mismos. Luego se continúa con el cálculo de valores medios y varianzas para todos los parámetros de EA y FA para todas las condiciones. Por último, se aplicarán dos técnicas de reducción dimensional, en primer lugar se estudiará la información mediante Componentes Principales (CP) y luego la otra variante de análisis adoptada se basa en la utilización de una red neuronal tipo SOM, con el fin de clasificar las diferentes condiciones de broca una vez entrenada con distintos lotes de datos medidos.

4.3.1 Selección de la información para analizar

Como se observó previamente, el taladrado efectuado en este estudio muestra dos etapas cuasiestacionarias que son aquella con AG y la posterior sin AG. En la primera no actúa el cincel mientras que en la segunda sí. El análisis efectuado en esta tesis se basa en el estudio de las señales de la etapa con AG, entonces por ese motivo se buscó un método eficaz para extraer la información correspondiente a este período, para cada variable y en cada condición. A continuación se describe la metodología utilizada para seleccionar la información relevante.

Tomando algunos de los parámetros de EA y graficándolos en función del tiempo se puede observar que no se distinguen variaciones que permitan diferenciar las dos etapas de manera precisa. De manera general para el proceso de taladrado sin AG se aprecia una dispersión creciente de los valores con el avance del ensayo, posiblemente debida al efecto del cincelado, que aporta una considerable deformación plástica y rozamiento haciendo que el taladrado se desarrolle de manera menos estable. Esto produce un aumento en el valor de las señales de EA y de su dispersión asociada, aunque no está claramente evidenciado el momento de transición entre un período y el otro. En la Fig. 4.14 se comparan algunos parámetros de la EA respecto del tiempo del ensayo en una condición de broca N. No ocurre lo mismo cuando se representa la FA en función del tiempo, evidenciándose dos etapas muy bien definidas con un considerable aumento del valor de la fuerza entre las etapas de taladrado “con” y “sin” AG, como se observa en la Fig. 4.15. Por lo tanto, se utilizó la FA como parámetro indicador para seleccionar los tiempos que delimitan el período de interés. Los lapsos determinados se asocian a las señales de EA, y de esta manera se selecciona la información perteneciente al período de taladrado con AG para todos los parámetros de EA. Una vez realizado esto se procede a extraer los parámetros de EA que son dependientes del tiempo, estos están relacionados con señales tipo explosión. En nuestros ensayos se tomaron ventanas fijas de 20 milisegundos de duración, estas ventanas están compuestas por señales continuas y/o superposición de señales tipo explosión, que provienen de un proceso de corte en condiciones cuasi-estacionarias (estables por el período de tiempo evaluado). Los parámetros Tiempo de Subida, Duración, Número de cuentas y Energía MARSE no serán entonces considerados para el análisis. Si lo serán la Fuerza de Avance (FA), la Frecuencia Media (FM), la Amplitud (AMP), el Valor Cuadrático Medio (RMS), Energía Absoluta (E.ABS) y la Potencia Media (PM). Por cada ensayo se extrajeron entre 850 – 1050 puntos o hits en este caso para su análisis. En el Apéndice A4 figura la cantidad de puntos seleccionados para cada ensayo y condición del filo.

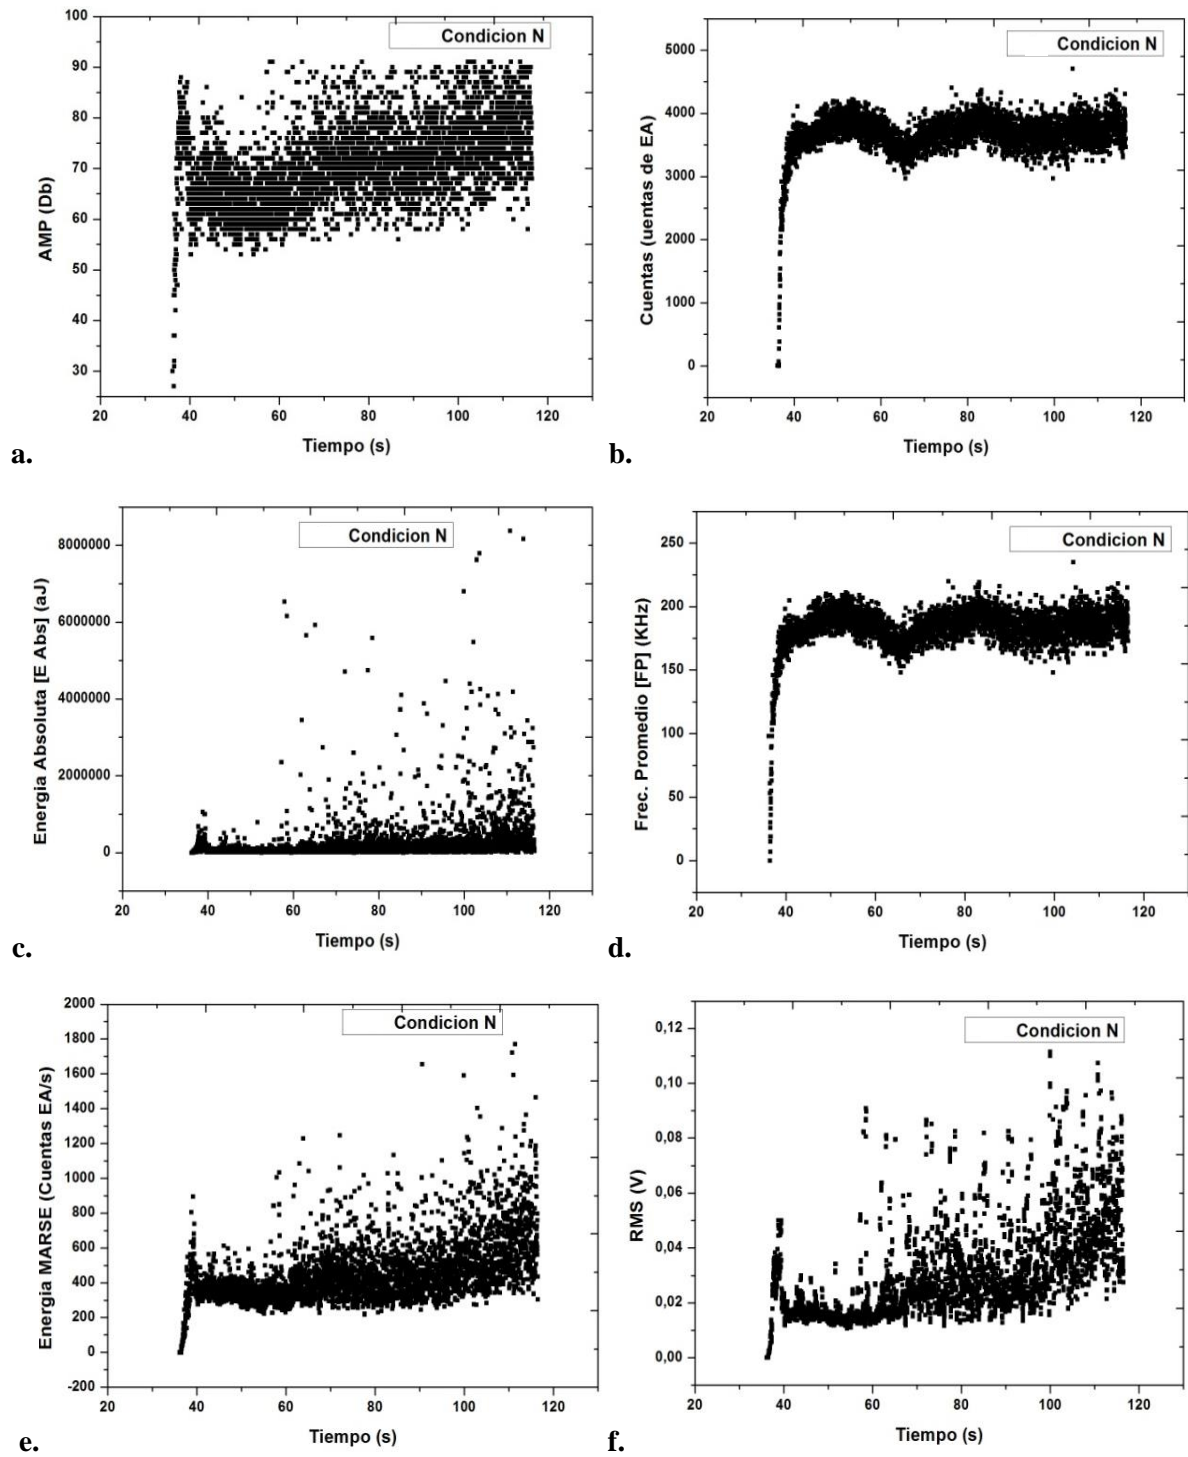


Fig. 4.14 Diferentes parámetros de EA respecto del tiempo para ensayos realizados con una broca N.
a. Amplitud. **b.** Cuentas de EA. **c.** Energía Absoluta. **d.** Frecuencia Media. **e.** Energía MARSE. **f.** RMS




Fig. 4.15. FA respecto tiempo para un ensayo con broca N.

4.3.2 Análisis de la distribución de la información

Una vez seleccionados los datos para cada condición, se buscó determinar a qué tipo de distribución estadística ajustaban. Esto se realizó de diferentes maneras. Por un lado, se hizo representando un histograma de los valores de las variables, donde la cantidad de intervalos usados es función de la raíz cuadrada del número de datos de la muestra (Fig. 4.16 a). Luego se superimprimió una distribución normal ajustada. Otra forma es graficando la distribución de los datos respecto del comportamiento normal representado por una línea recta a trazos (Fig. 4.16 b). La distancia de los datos respecto de esta línea es considerada la lejanía respecto un comportamiento normal. Por lo tanto, si la función de probabilidad no tiene distribución normal, introducirá una curvatura en la gráfica de los puntos, que no copiará la línea recta a trazos.

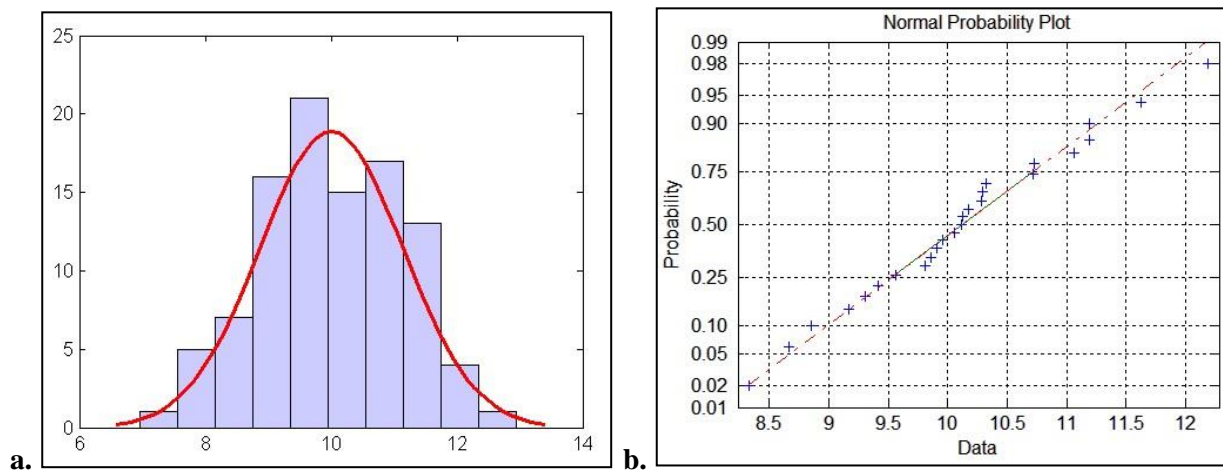


Fig. 4.16 Ejemplos de diferentes formas de evaluar la distribución del lote de datos (Matlab 2008).

4.3.3 Análisis de Correlación Lineal

En este análisis, se estudió la correlación entre parámetros con el fin de detectar información redundante, en la búsqueda de una reducción dimensional. Para esto se calcularon los coeficientes de correlación lineal entre las variables, entendiendo que aquellos parámetros que se “mueven” de manera similar (altamente correlacionados) aportan información redundante del proceso, por lo que solamente se deberá considerar uno solo de ellos para representar el fenómeno. Estas variables altamente correlacionadas van a diferir solamente en un factor constante que puede ser estimado, por lo que se puede trabajar únicamente con una sola de estas dos variables, lo que brinda economía de cálculo a la hora analizar los datos. La ecuación que calcula este coeficiente de correlación se define como:

$$Coef_{Corr(x,y)} = \frac{Cov(X,Y)}{\sigma_x \cdot \sigma_y}$$

Donde X e Y son las medias de los parámetros considerados, σ_x y σ_y los desvíos estándar respectivos.

4.3.4 *Análisis por cálculo del valor medio, varianza y desvío estándar*

Establecidos los segmentos de señales y parámetros que serán considerados, se procede a calcular valores estadísticos para cada parámetro y ensayo realizado. Estos son el valor medio, la varianza y la desviación estándar. Luego se recalculan los valores medios de cada condición de manera de obtener un solo valor representativo para cada parámetro y condición. Esto permite tener una reducción dimensional del problema como se muestra en la Fig. 4.17. Luego, estos valores se grafican para cada condición de manera de poder comparar sus comportamientos.




Fig. 4.17 Esquema de reducción dimensional mediante el cálculo de valores medios.

4.3.5. *Análisis por Componentes Principales (CP)*

Mediante esta técnica se pretende clasificar los diferentes casos de desgaste, analizando la varianza asociada a los parámetros anteriormente seleccionados. El principio de estudio de esta técnica se basa en suponer que la información de mayor valor está relacionada con la mayor varianza del proceso o experimento. Para poder llevar a cabo este análisis se debió preparar la información de manera adecuada para ser analizada. Esto requirió, reunir toda la información perteneciente a las diferentes condiciones de broca en una sola matriz de datos. La dimensión total de la matriz quedó establecida en 24.535 vectores dato con 6 parámetros cada uno (24535 x 6). En la Tabla 4.4 se muestra como ejemplo un fragmento de la lista donde figuran 5 vectores de datos de los 24.535 con sus 6 dimensiones o parámetros.

Tabla 4.4 Detalle de vectores dato con sus 6 dimensiones.

	FA	F Med	AMP	RMS	ABS-ENERGY	PM
1	25.9898	4752	78	0.0516	503536	0.0539
2	25.2183	4567	69	0.047	170187	0.0341
3	24.495	4706	76	0.045	468692	0.04925
4	25.5799	4634	80	0.0464	780466	0.05935
5	26.3032	4691	77	0.0462	344455	0.04515

Considerando la información obtenida de los gráficos de normalidad se realizaron dos tipos de escalados. En el primero, denominado Autoescalado, donde se centraron los datos respecto a los valores medios para cada parámetro. Luego se operó utilizando el desvío estándar de los mismos con el fin de homogeneizar unidades y normalizar el lote de datos. El segundo escalado, denominado Mínimax, relativiza todas las mediciones entre 0-1 según los valores máximos y mínimos de la medición para cada parámetro. Con las dos matrices de datos escaladas de diferente manera se procedió a aplicar la técnica de CP en ambas matrices. El primer paso consistió en evaluar el porcentaje de captura de varianza para cada CP, graficando únicamente los CP que agrupen una gran porción de la varianza del ensayo por ser los más representativos del fenómeno estudiado. Una vez seleccionados los CPs, se graficó toda la información en estos nuevos ejes coordenados y se estudió la distribución espacial de la misma.

4.3.6. *Análisis mediante Redes Neuronales*

La detección y el análisis de la EA en base a la parametrización de la onda resultante produce una amplia cantidad de información con parámetros simultáneos que eventualmente pueden describir una condición específica de proceso. Estos parámetros (en lo posible) no deben ser evaluados variable a variable, sino, que su análisis debe ser de manera simultánea. Lo anterior conlleva a que el proceso de análisis sea complejo, sin considerar que además la información de la EA es altamente dependiente de la configuración experimental, el material, la geometría y la posibilidad de existencia de fuentes de EA que no estén directamente correlacionadas con el caso de estudio [Ramasso y otros (2012)]. Por lo tanto, no existen señales con características universales de los diferentes eventos, (en este trabajo asociado a los diferentes niveles de desgaste), pero en condiciones constantes de ensayo existen similitudes entre las señales adquiridas que permiten su clasificación [Godin y otros (2005)].

En el presente trabajo se utilizó una red neuronal tipo mapa auto organizado (SOM), también denominada Kohonen para clasificar los tipos de señales adquiridas de diferentes condiciones de broca considerando varios parámetros de manera simultáneamente.

Esta red cuenta con las características descritas en el capítulo introductorio dando como resultado un mapa en dos dimensiones donde se establece la clasificación de las señales en base a un posicionamiento topológico de la información. A continuación se describirá el pre procesamiento de los datos necesarios para ingresar la información a la red, el criterio de definición de tamaño de las sub matrices, la configuración de arquitecturas probadas y las peculiaridades de este tipo de red neuronal.

Para explicar el procesamiento de las señales llevado a cabo mediante redes neuronales, se dividirá esta sección en dos partes principales:

- Preparación y selección de los datos para entrenamiento y predicción.
- Entrenamiento de las diferentes arquitecturas de red neuronal.

Estos puntos son fundamentales para comprender el procesamiento de los datos, el acondicionamiento y manejo de los mismos para el entrenamiento y la predicción, la comparación de la efectividad de la red y la forma de interpretación de los resultados de salida de la red neuronal.

4.3.6.1 *Preparación y selección de los datos para entrenamiento y predicción*

El primer paso para el análisis de la información es la preparación de los datos para entrenamiento y predicción con que se alimentará la red neuronal. La estructura general de las matrices en ambos casos es idéntica y tendrá una dimensión de $n \times 8$. Esto significa que n vectores de información tendrán asociados 8 parámetros característicos. Las n mediciones corresponden a los datos tomados para cada condición de broca que ingresarán de manera sucesiva para ser clasificados.

De los 8 parámetros que definen un vector, 5 de ellos corresponden a la EA y fueron seleccionados mediante las técnicas mencionadas anteriormente, el sexto corresponde a la FA y los dos restantes (7 y 8) son etiquetas identificadoras. Una de ellas identifica al vector de información en particular y la otra corresponde a un código ASCII que indica a qué tipo de condición de ensayo pertenece ese vector de información (N, CM, CE, BA y EG). Finalmente el lote de datos quedó compuesto por una matriz con dimensión de 24.535×8 vectores para todos los ensayos evaluados en la etapa de taladrado con AG. A continuación, estos vectores fueron mezclados de manera aleatoria para que no ingresen en forma secuencial y ordenada a la red.

Con la matriz general de datos aleatoriamente ordenada se pudo comenzar el proceso de extracción de las *sub-matrices* de diferentes dimensiones para realizar el entrenamiento y la predicción. En la Tabla 4.5 se puntualiza el tamaño de las sub matrices utilizadas. Esta diferencia afecta de manera directa al tiempo de cálculo necesario para el entrenamiento de la red, siendo prácticamente despreciable el impacto en la predicción. Se debe aclarar que todas las sub matrices fueron extraídas de diferentes partes de la matriz

aleatoria original de manera que no haya vectores de datos repetidos en los diferentes entrenamientos ni tampoco en los procesos de predicción.

Tabla 4.5 Tamaño y cantidad de matrices para entrenamiento y predicción.

TAMAÑO DE MATRIZ	MATRICES DE ENTRENAMIENTO	MATRICES DE PREDICCIÓN
250 x 8	---	4
500 x 8	2	2
1000 x 8	4	2
1000 x 7	6	---
1500 x 8	2	1

Los criterios de selección resultantes para determinar los tamaños de las *submatrices* para entrenamiento y predicción utilizaron una base conceptual de funcionamiento de la red y pruebas empíricas de la misma. Para esto se evaluaron los porcentajes de errores de mezclado y de norma, así como el tiempo de entrenamiento con las diferentes configuraciones, y la evolución de la distribución del mapa resultante. Entonces se buscó tener un justo compromiso entre el tiempo de procesamiento, y los niveles de error en los entrenamientos que dieran como resultado un bajo error en la predicción y una precisa separación gráfica de la información. Esto último, está referido a una separación en clústeres con poca mezcla de los casos de estudio. En el análisis fueron considerados los efectos correspondientes a la variación del tamaño muestral. Según se modifique el tamaño de la sub matriz, será más o menos representativa de la totalidad de casos evaluados. Esto influye directamente en la cantidad y variedad de casos considerados por la red, donde se asume que estadísticamente cuanto más grande sea la *submatriz* seleccionada, tendrá más variedad de vectores de información y por lo tanto, en el entrenamiento la red “aprenderá a reconocer” una mayor cantidad de situaciones. Esto es independiente de la cantidad de épocas con las que se entrene a la red. Si bien la efectividad del entrenamiento está ligada al número de épocas de procesamiento (hasta cierto límite), la variedad de casos que procesarán serán siempre los mismos. Por lo tanto, la eficiencia de la red en la predicción de diferentes situaciones se verá más comprometida en el caso no contar con un lote de entrenamiento suficientemente variado, aunque la cantidad de épocas de procesamiento sea extensa.

La selección del tamaño de las *sub matrices* depende de varios factores, con lo cual, para comenzar a delimitar la problemática se hará referencia a reglas del arte en el proceso de entrenamiento y predicción de RN, así como de las necesidades y posibilidades reales de tomar mediciones en un entorno industrial donde deba ser evaluado el estado de la herramienta. Por lo general se considera que el tamaño del lote de predicción debe ser aproximadamente una tercera parte del de entrenamiento. De esta manera, se toma un muestreo de datos para entrenamiento más amplio que la cantidad cubierta por el lote seleccionado para predicción. Esto hace que la red aprenda una variedad mayor de situaciones que luego podrán ser reconocidas por las neuronas de la red a la hora de clasificar la información del lote de predicción. La información del lote de predicción no debería ser la misma que la del lote de entrenamiento, salvo caso que se cuente con muy poca cantidad de datos.

El monitoreo en línea del estado de la herramienta en un proceso de mecanizado debe ser hecho de manera rápida e idealmente tomando la menor cantidad de datos posible, desde el punto de vista de la eficiencia. Si el proceso es realizado en altas velocidades y tiempos cortos, puede ser difícil hallar etapas de medición que cumplan con la premisa de corte “cuasiestacionario” donde las señales incorporen información que permita distinguir la condición de la herramienta. Esto dependerá en general de la operación de mecanizado a realizar (material, dimensiones, tipo de operación, parámetros operativos, etc.) además de las características técnicas del centro de mecanizado como su potencia, nivel de tecnología y herramental utilizado. Tomadas en cuenta estas consideraciones, se observa que resultaría difícil cubrir toda la variedad de situaciones de mecanizado existentes en un único modelo. Se puede entonces tomar

un tamaño de sub matriz que sea suficientemente grande como para que la información brindada sea representativa pero no tan extensa que necesite mantener las condiciones estables de corte durante largos períodos de tiempo. En la toma de datos de los ensayos realizados, 250 puntos equivalen a 5 segundos de señal. Relacionando este último valor con la duración de un proceso de mecanizado arbitrario que tenga una duración de 5 segundos en una condición determinada de trabajo (velocidad de corte, avance, dirección, material, etc.) se puede llegar a asimilar una condición de proceso cuasi estable de donde se obtiene una medida indirecta representativa del proceso. Este tiempo de captura de datos se estableció como un mínimo razonable que determinó las menores dimensiones de las sub-matrices para predicción (250 x 8 vectores dato aleatoriamente ordenados).

El monitoreo en tiempos menores es posible sin disminuir la cantidad de datos, esto se puede realizar aumentando la velocidad de muestreo de la señal, lo que resultará en una ventana temporal más pequeña. Por otro lado, si suponemos que el deterioro de la herramienta se produce en un intervalo de tiempo inferior a 5 segundos, el deterioro debe ser rápido como en los casos de alta fricción, o catastrófico como en la rotura abrupta, pero no una condición normal de corte. Estas señales, además, son mucho más características y fácilmente reconocibles que un proceso de gradual y consecutivo deterioro que eventualmente finalice en una rotura catastrófica. Conforme a lo anterior y al desarrollo de los ensayos, las *sub matrices* de predicción varían dimensionalmente desde $n = 250, 500, 1000$ y 1500×8 vectores dato, de modo de poder contrastar un comportamiento desde una reducida a una amplia variedad de casos. Para el proceso de entrenamiento se excluyeron las *sub matrices* de dimensiones de 250×8 vectores por ser pocos datos para el desarrollo de esta etapa. Luego en base a la experiencia que brindo el análisis por CP se realizó un escalado Minimax para normalizar la información antes de ser ingresada a la red.

Como casos separados de estudio y con el objetivo de evaluar el peso relativo de cada variable sobre el proceso de aprendizaje y clasificación de la red, se seleccionaron 6 submatrices de 1000 datos c/u con una reducción dimensional. A estas sub matrices se les sustrajo sistemáticamente uno a uno los parámetros de EA y FA con el objetivo de poder evaluar la importancia relativa de la variable faltante en el proceso de clasificación. Las dimensiones finales de las sub matrices quedaron establecidas en 1000×7 vectores dato. Luego se entrenó la red con los diferentes parámetros faltantes y se realizó una comparación de los resultados.

4.3.6.2. *Entrenamiento de las diferentes arquitecturas de red neuronal*

La red neuronal utilizada también denominada SOM (Self Organized Map) fue entrenada de manera secuencial con las diferentes submatrices. Se comenzó por las de dimensiones de 500×8 vectores hasta llegar a las de 1500×8 . Esto permitió ir variando la conformación de la red y ajustar sucesivamente su configuración hasta encontrar un conjunto de parámetros de arquitectura que minimicen los errores con respecto al tiempo de cálculo. Los resultados de las diferentes configuraciones son evaluados en base a los porcentajes de error de norma y de mezclado para el entrenamiento y luego para la predicción. Finalmente el verdadero error de la red es el obtenido en la etapa de predicción y no en el entrenamiento. Este último se utiliza para comparar la eficiencia entre entrenamientos con diferentes arquitecturas, a fin de poder seleccionar aquella que demuestre mejor desempeño en esta etapa en particular. Como se mencionó anteriormente, los errores mensurados son dos, el primero es llamado *error de norma* que representa la distancia promedio de los pesos de todas las neuronas respecto a los vectores dato ingresados en la última época. Es decir que indica que tan lejos o cerca se encuentra la respuesta de la red respecto de la información ingresada en el último período. Cuanto más parecidos sean los pesos de las neuronas a los vectores dato ingresados, menor será la distancia que entre ellos los separa. Esto se puede apreciar en la Fig. 4.18 donde se esquematiza la distancia entre dos vectores genéricos. La red neuronal procesa la información tratando de minimizar esta distancia, y por estar los datos normalizados, el valor de este error varía entre 0 y 1.

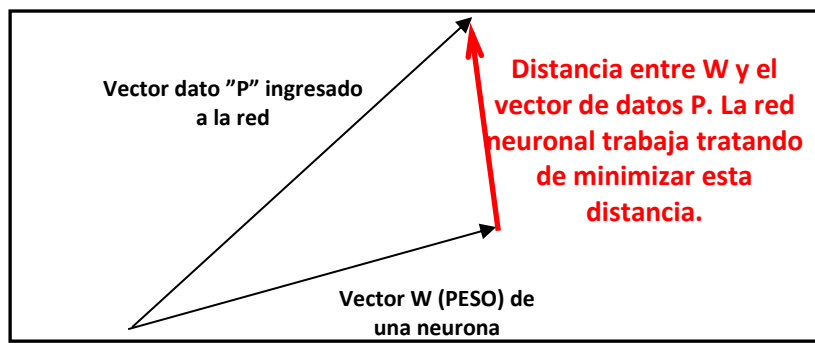


Fig. 4.18 Distancia angular entre w y el vector de información.

El segundo tipo de error considerado llamado *error de mezclado* o "*mixing error*", ocurre cuando la red clasifica objetos diferentes en el mismo casillero. Por ejemplo, si esta viene clasificando objetos tipo 1 en un dado casillero y eventualmente coloca un objeto tipo 2 en la misma casilla. Esto sucede cuando vectores de información pertenecientes a diferentes condiciones de broca activan la misma neurona, lo que significa que posiblemente uno de ellos haya sido erróneamente clasificado por la red por ser muy similares entre sí. Este error se mide con un valor porcentual respecto a todos los casos ingresados a la red. Para nuestro análisis se estableció una cota de error máxima del 5 % en la predicción. Este es un margen aceptable de confusión para realizar un proceso de modelización. En cuanto al error de norma se buscará que sea bajo, mas no es determinante debido a que la red podría no ajustar sus pesos completamente a los valores de entrada e igualmente clasificar los casos de manera satisfactoria.

En la Tabla 4.6 se muestran todas las características modificables de la red y los valores con los cuales fueron hechos los entrenamientos. Estos parámetros fueron probados de manera combinada para identificar el conjunto que diera como resultado el menor porcentaje de error y la mayor eficacia en el tiempo de procesamiento.

El proceso de entrenamiento se comenzó utilizando las sub matrices de 500 x 8 conjuntamente con las redes de menor tamaño, 900 y 1600 neuronas (30 x 30 y 40 x 40) lo que permitió tener valores preliminares de error de manera relativamente rápida que indicaron la dirección en la mejora de la arquitectura de la red. A continuación se enumeran los lineamientos que se siguieron, basados en el conocimiento y en la observación del comportamiento de la red en las primeras etapas del entrenamiento.

- I. Cuanto más grande es la malla de clasificación mejor separa los grupos de información en detrimento del tiempo necesario para el entrenamiento.
- II. Si la malla es lo suficientemente grande, es muy conveniente aumentar la vecindad.
- III. A igual tiempo de procesamiento, es más conveniente ampliar sub matriz de datos que aumentar la cantidad de épocas.
- IV. Si la sub matriz tiene una importante cantidad de datos es mejor que las correcciones de los pesos sean suaves aunque tarde más tiempo en converger.
- V. La función de ajuste de pesos tipo gaussiana es la que mejor se adaptó al presente estudio.
- VI. En este caso el error relacionado con las diferentes geometrías (planar y toroidal) varía muy poco con respecto a la modificación de otros parámetros pero visualmente queda mejor definido el mapa generado a partir de una geometría planar.

En la Fig. 4.19 se muestran como ejemplo dos gráficos con mapas típicos que se obtienen como resultado del entrenamiento de dos redes de 1600 neuronas (40 x 40) alimentadas con la misma sub matriz (500 x 8). Se pueden observar regiones de diferentes colores que corresponden a la clasificación de los vectores de información contenidos en la submatriz y que pertenecen a las diferentes clasificaciones determinadas por red. En las distribuciones representadas se muestran una red planar en la Fig. 4.19 a y una toroidal en

la Fig. 4.19 b. En el segundo caso se puede observar una aparente discontinuidad en los grupos clasificados. La correcta interpretación es la demarcada mediante flechas del color correspondiente que indican la continuidad de los grupos basados en la geometría toroidal. En la Tabla 4.7 se detallan los porcentajes de error de cada red y la arquitectura completa de las mismas.

Tabla 4.6 Valores de parámetros de arquitectura probados durante el entrenamiento.

PARÁMETRO DE LA RED NEURONAL	CARACTERÍSTICAS
	30 x 30 Trama Rectangular
Tamaño de la Red	40 X 40 Trama Rectangular
	50 X 50 Trama Rectangular
Forma de la Malla	Planar y Toroidal
Tamaño de la vecindad	5 – 11 – 15 – 17 Vecinos
Función de Corrección de Vecindad	Constante – Triangular – Gausiana
Máxima corrección de pesos	0.5 – 0.7 – 0.9
Mínima corrección de pesos	0.1 – 0.05
Valor inicial de pesos	0.01 – 0.0001
	Por vector de entrada
Ajuste de pesos	Por época
	Por vector de entrada y época
Cantidad de épocas	500 - 1000




Fig. 4.19 a. Geometría Planar. **b.** Geometría Toroidal.

Tabla 4.7 Detalle de las arquitecturas consideradas en las Fig. 4.19 a y b.

CARACTERÍSTICA DE LA RED	Fig. 2.18 a	Fig. 2.18 b
Error de Mezclado	6%	7.3%
Error de Norma	0.016686	0.0166362
Tamaño de la Red	40 x40	40 x40
Forma de la Malla	Planar	Toroidal
Tamaño de la vecindad	5	5
Función de Corrección de Vecindad	Gausiana	Gausiana
Máxima corrección de pesos	0.7	0.5
Mínima corrección de pesos	0.1	0.1
Valor inicial de pesos	0.001	0.001
Ajuste de pesos	Por vector y Época	Por vector y Época
Cantidad de épocas	500	500

Sobre el mismo ejemplo, el error de mezclado para el caso mostrado en la Fig. 4.19 a indica que en promedio 60 por cada mil datos ingresados serán mal clasificados, mientras que para el caso 4.19 b el número asciende a 73. Este nivel de error (si bien es bajo) está por encima del objetivo establecido de un 5 % para el entrenamiento y predicción. Por este motivo se debe seguir mejorando la configuración de la red. El error de norma en ambos casos es muy bajo indicando que la red “aprendió” de manera satisfactoria a reconocer los vectores de entrada ajustando sus pesos. Si observamos la distribución topológica de los grupos, en ambos mapas se puede apreciar la clasificación de las 5 condiciones de brocas estudiadas. Cualquiera de las dos geometrías serán válidas, pero se elegirá la planar de forma constante en los entrenamientos por suponerse una más directa visualización de los grupos en el gráfico. La evolución de los entrenamientos con diferentes arquitecturas será evaluada teniendo en cuenta el valor de los errores y el análisis visual que resulta de los mapas generados donde se considera la mezcla gráfica de las neuronas activadas y las zonas limítrofes entre sí, más que la forma de los grupos.

Capítulo 5

RESULTADOS Y DISCUSIÓN

En el presente capítulo se detallan los resultados de las mediciones de distintos parámetros de la EA y de la FA realizadas durante los ensayos de taladrado. Además se muestran los resultados de los análisis estadísticos que comprenden valores medios, varianzas y desvíos estándares. Luego se detalla la aplicación de distintas herramientas como componentes principales y la utilización de redes neuronales para clasificar la condición de la herramienta.

5.1 Caracterización de las etapas del corte por medio de la fuerza de avance

Durante la medición de la FA se ha observado el sensible cambio de esta magnitud según los diferentes estadios del proceso de taladrado. Por esta razón se utilizó este parámetro para identificar y seleccionar de manera simple y precisa los tramos de datos provenientes del taladrado en la zona con AG, que fueron estudiados en secciones posteriores. Considerando la reacción medida por la celda de carga, mostrada en la Fig. 5.1, se puede describir en forma cualitativa el desarrollo del ensayo. En el inicio existe una etapa transitoria donde los filos principales de la broca hacen un contacto intermitente con la probeta (Etapa 1), luego se produce el taladrado estable con AG y sin efecto de cincel (Etapa 2). Posteriormente existe un segundo transitorio debido a la finalización del agujero guía y al comienzo del proceso de cincelado (Etapa 3) donde se observa un claro y esperable aumento del valor de la FA. Finalmente, luego de avanzar más allá de esta zona de transición, la broca comienza el proceso de taladrado estable sin AG, sumándose la acción del cincel a los filos principales de corte (Etapa 4). Estas cuatro etapas son distinguibles por la FA para todos los ensayos realizados.




Fig. 5.1. Etapas del taladrado en grafico FA vs Tiempo.

En el Apéndice A3 se pueden encontrar los gráficos de la FA para el resto de las condiciones de broca donde se reconocen las cuatro etapas anteriormente mencionadas. Adicionalmente se puede observar de manera general un aumento de la FA en los casos con filo deteriorado, con respecto a la broca con filos en óptimo estado (Brocas N). Esto será detallado más adelante cuando se consideren para el análisis los valores medios de los parámetros para todas las condiciones.

La selección de la información utilizada en los análisis posteriores se basó en la identificación de los intervalos temporales que, asociados a las señales de EA, pertenecían al período con AG (zona 2), en un intervalo en el cual el proceso de corte se mantuviera estable y cuasi-estacionario. Por tal motivo no se tuvo en cuenta la información aledaña a las zonas de transición (zonas 1 y 3). El detalle de las señales seleccionadas se encuentra en el apéndice A4 donde se describen los intervalos tomados de la señal así como la cantidad de puntos extraídos.

5.2 Análisis de normalidad de las señales de EA y FA

El análisis de comportamiento normal es llevado a cabo para evaluar si la distribución de los parámetros responde a este tipo de comportamiento o no. Esto se realizó para las diferentes variables en todas las

condiciones de broca. Los parámetros que se exponen en la Fig. 5.2 muestran la distribución de la variable discretizada (barras azules) contrastada respecto de la distribución que deberían tener si su comportamiento fuera normal (línea roja continua). De manera semejante, en la Fig. 5.3 se refleja cómo y cuánto se distancian los datos del parámetro considerado respecto de un comportamiento normal simbolizado por una línea recta a trazos, también sobreimpresa sobre el gráfico. Estos resultados corresponden a parámetros medidos en condición de broca (N) debido a que es la condición de corte más estable y una de las de mayor interés. En las Figuras 5.2 b y 5.3 b se observa que el parámetro de EA denominado FM es el que más se aproxima a un comportamiento normal. La Amplitud muestra un menor acuerdo con esa distribución (Fig. 5.2 c y 5.3 c). Luego, las figuras que representan los parámetros RMS, Energía Absoluta y PM se asemejan a otro tipo de distribución, posiblemente Lognormal.

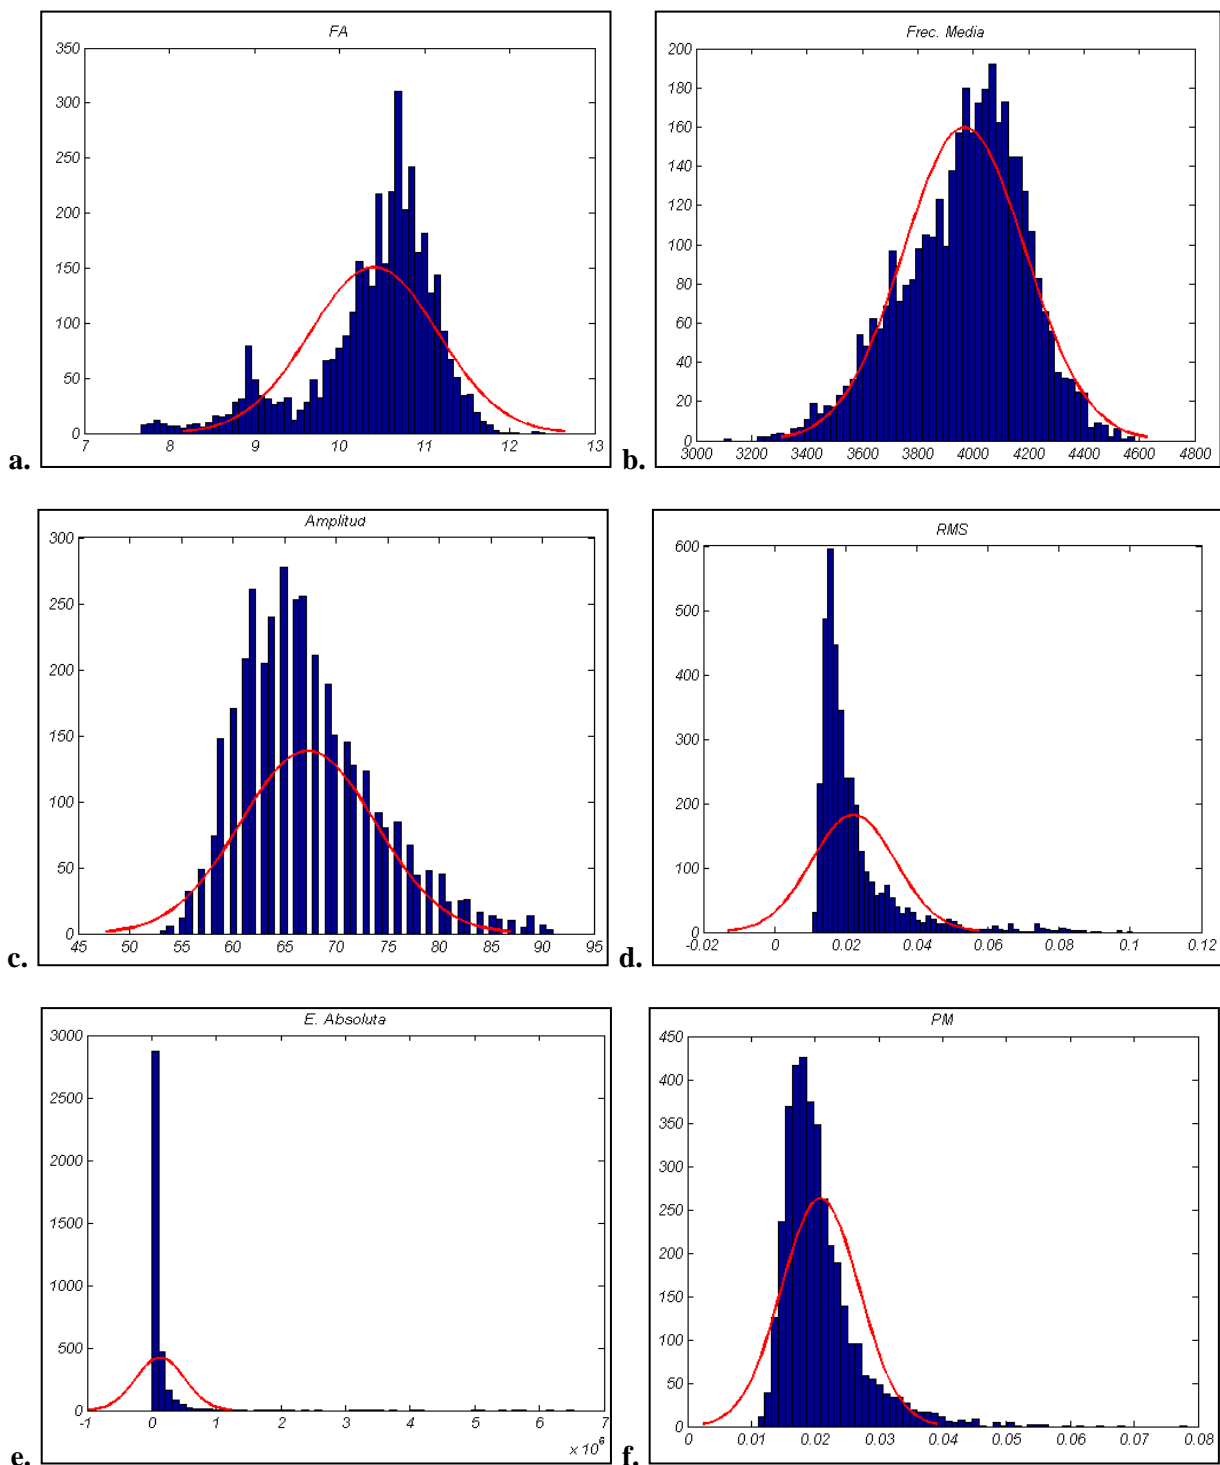


Fig. 5.2 Histogramas con distribución de parámetros para broca N. **a.** FA. **b.** FM. **c.** AMP. **d.** RMS. **e.** EABS. **f.** PM.

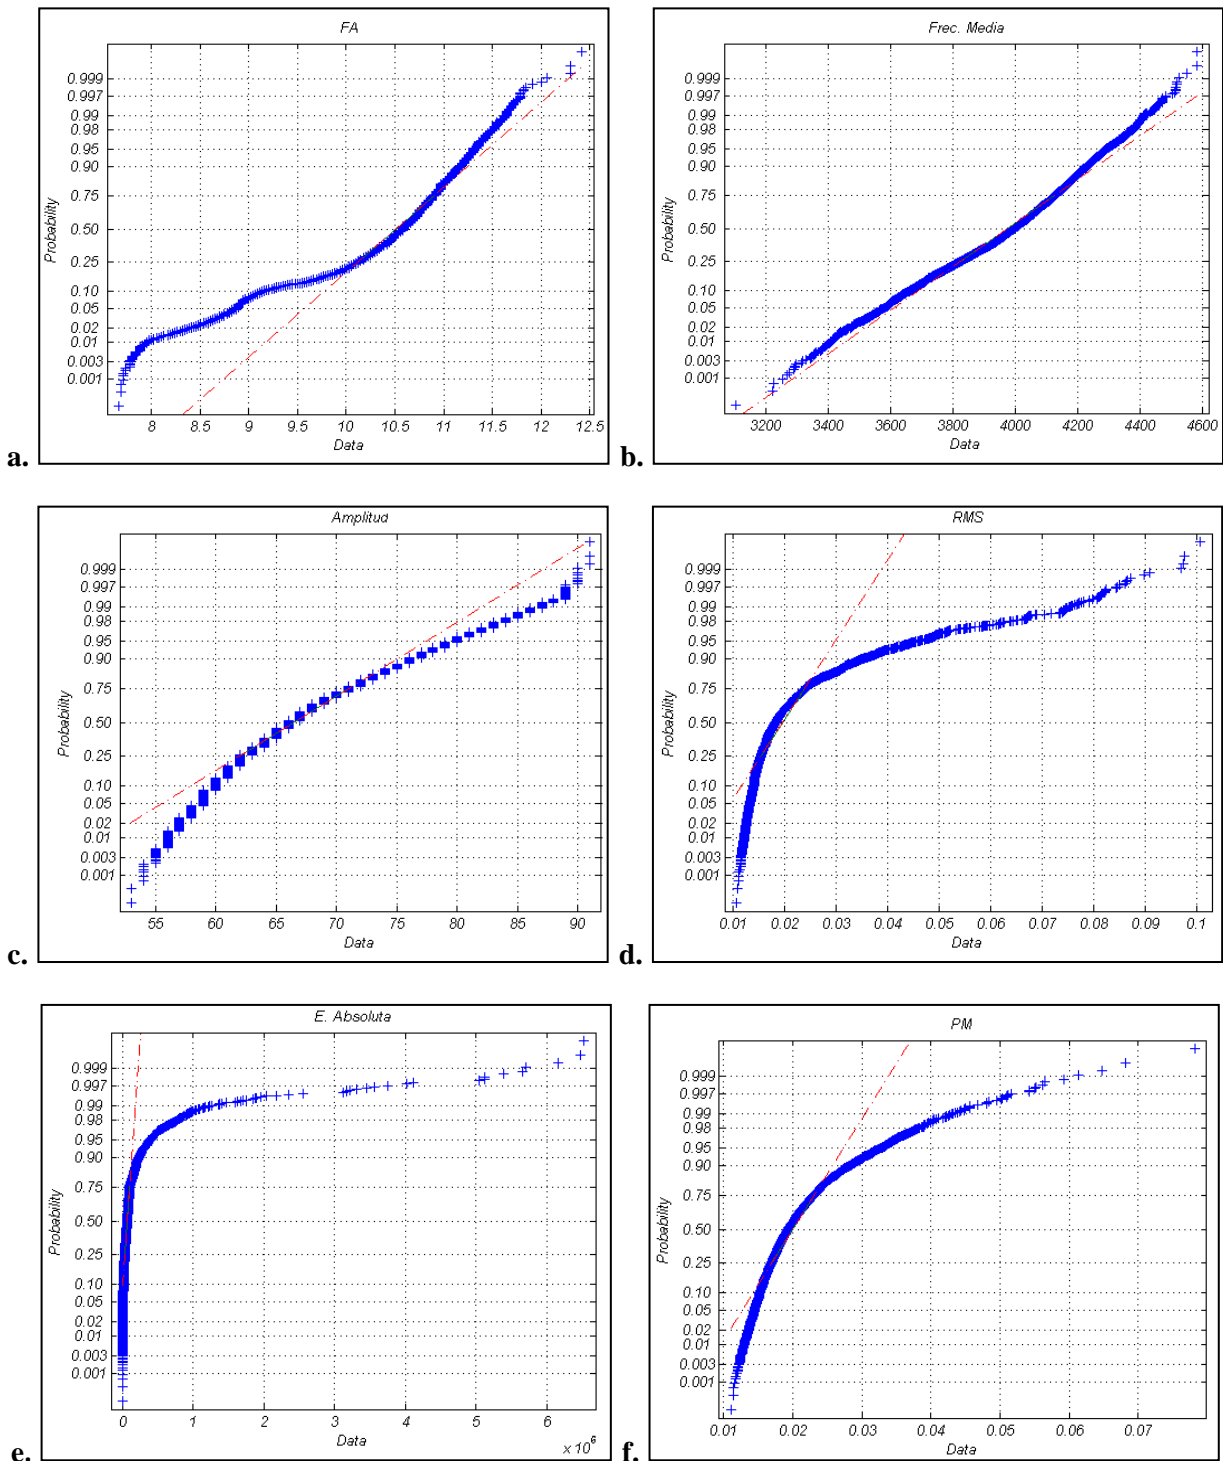


Fig. 5.3 Análisis de normalidad de parámetros para broca N. **a.** FA. **b.** FM. **c.** AMP. **d.** RMS. **e.** EABS. **f.** PM.

Evaluando el comportamiento con respecto a los ensayos de brocas con filo deteriorado (Apéndice A5), se observa que la FA se aproxima más a un comportamiento normal para los casos CE, CM, EG y BA que para el caso de broca N. Si se compara el RMS se observa que los casos CM, CE y EG parecerían ser mucho más normales que los casos en condiciones de broca N y BA. El parámetro Energía Absoluta se comporta de manera semejante a una distribución Log normal sin importar la condición de broca seleccionada. Luego de observar la forma en la que distintas condiciones y parámetros aproximan su comportamiento a una distribución normal, se concluye que no se observa un patrón definido que permita hacer algún tipo de clasificación de casos.

5.3 Análisis de correlación lineal y determinación de los parámetros a utilizar

Este método permite observar el grado de correlación lineal entre los comportamientos de las variables, es decir, la forma y el grado de semejanza. En la Tabla 5.1 se presenta un resumen del par de parámetros que obtuvieron una correlación superior a 0.7 y la condición de la broca correspondiente a estos casos. Estos valores fueron calculados en base a la información adquirida en una sesión de 12 ensayos para todas las condiciones de broca. En el Apéndice A6 se encuentra un desarrollo más extenso de los análisis de correlación en el cual se muestran las matrices completas con los parámetros de EA y FA para los cinco casos de condiciones de broca.

Tabla 5.1 Valores de correlación mayores al 70 % entre parámetros con diferentes condiciones de broca.

NUEVA [N]	PM	AMP	0.7748
CRAT. MECANICO [CM]	PM	AMP	0.7404
	PM	ABS-ENERGY	0.8583
CRAT. E. EROSION [CE]	PM	AMP	0.7778
	PM	ABS-ENERGY	0.8955
BROCA ACHAFLANADA [BA]	PM	AMP	0.7252
	PM	ABS-ENERGY	0.8028
ESQUINA GASTADA [EG]	ABS-ENERGY	AMP	0.7405
	PM	RMS	0.7270
	PM	ABS-ENERGY	0.8146

En la Tabla 5.1 se puede observar una alta correlación mutua para distintas combinaciones de los parámetros AMP, PM y EABS, que no se da de manera simultánea en todas las condiciones, como por ejemplo en el par PM-AMP que se encuentra presente en todas las condiciones excepto la de EG y en el par PM-EABS que no aparece para la condición N. A su vez, la alta correlación entre AMP y EABS con respecto a la PM no implica una alta correlación entre ellas dos (AMP/EABS). El único caso que muestra este comportamiento es la condición de EG. De lo anterior, se concluye que si bien existen variables con un alto valor de correlación entre ambas, no puede ser determinado un patrón de correlación lineal que se defina claramente en todas las condiciones de ensayo.

Adicionalmente, suponiendo que todas las variables aportan información en una medición, al aumentar el número de parámetros la evaluación realizada para una condición en particular podría ser más completa. Esto es en desmedro de la eficiencia de cálculo. Por lo tanto, si el impacto de considerar algunos parámetros adicionales es bajo con respecto a la eficiencia de cálculo, es conveniente operar con la mayor cantidad de variables posible.

Teniendo todo lo anterior en consideración es que se definen las 6 variables que serán utilizadas y analizadas para identificar las 5 diferentes condiciones de broca. Estas son:

1. Fuerza de Avance [FA]
2. Amplitud [AMP]
3. Frecuencia Media [FM]
4. Valor cuadrático medio [RMS]
5. Energía Absoluta [EABS]
6. Potencia Media [PM]

5.4 Cálculo de valores medios de los parámetros de EA y FA

A continuación se muestran y analizan los resultados de las variables medidas para las cinco condiciones de broca en base al cálculo de estadística descriptiva (valores medios, varianzas, desviaciones estándar) y las relaciones observadas entre ellos. Se detallará la media del parámetro considerado (en el período de taladrado con AG) para cada condición con su desviación estándar o varianza, según el caso.

En la Fig. 5.4 se expone el valor de la FA para todos los ensayos realizados con todas las condiciones de broca.




Fig. 5.4 Representación del valor medio de la FA para todos los ensayos en diferentes condiciones de broca.

Por motivos de optimización en la representación gráfica, dada la gran cantidad de datos, se procedió a promediar las distintas mediciones de cada ensayo realizados con iguales condiciones de filo de la herramienta, obteniendo un solo valor representativo para cada condición como se muestra en la Fig. 5.5. Este procedimiento se realizó para todos los parámetros considerados. Los detalles de la información sin promediar están disponibles en el Apéndice A7.

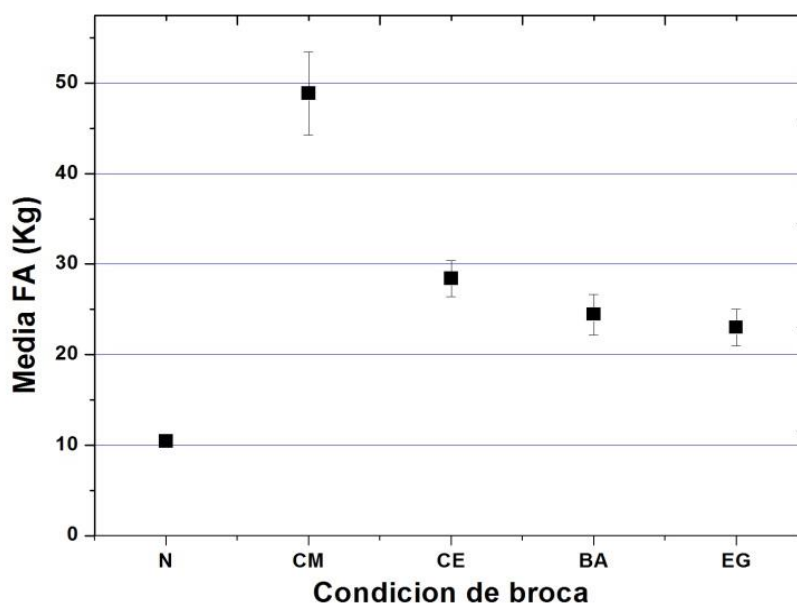


Fig. 5.5 Valor medio de la FA para cada condición de broca ensayada.

Analizando el comportamiento de la FA en función de la condición de la broca, como se muestra en la Fig. 5.5, se puede observar que la broca con filo N aplica menos FA para realizar el orificio y en base a esto, cualquier deterioro producido de los filos reflejara un incremento en este parámetro.

Una herramienta de geometría afilada produce un corte uniforme que genera en la zona anterior al corte con deformación plástica reducida y muy focalizada en el plano de corte. En esta condición, la región de pre-flujo plástico es pequeña. Al introducir un defecto en los filos de corte, la deformación plástica que sufre el material tanto cortado como el que permanece aún sin cortar en la pieza es mucho mayor, por lo tanto la energía involucrada en el proceso de corte aumentará. Los procesos friccionales relacionados con el contacto entre la cara y el flanco de la herramienta también se incrementarán según el tipo de defecto considerado. Si centramos la observación en los casos con filos deteriorados, la condición de CM se distingue con respecto del resto de manera muy clara, pero los casos CE, BA y EG no pueden ser separados de manera práctica. Al analizar los parámetros de EA graficados en la Fig. 5.6, se puede observar de manera general que los casos de brocas N son identificables por el bajo valor de cada una de las variables consideradas. Esto es atribuible en parte a las mismas causas de proceso descritas para la FA. También debe considerarse que el proceso de extracción del material (viruta) produce EA registrable y en una condición de corte estable (broca N), su formación y desprendimiento es relativamente ordenado y progresivo. El material sale de manera continua en forma de chip con poca deformación plástica general y mucha deformación concentrada en el plano de corte, para luego ir curvándose y conformar virutas de largas dimensiones (Fig. 5.7 a).

Esta forma definida y típica de un correcto proceso de corte en material dúctil evidentemente genera niveles bajos de EA, mientras que un filo deteriorado produce mucha más deformación en la viruta, endureciendo el material, cambiando la geometría de salida del mismo y haciendo que se fracture de forma anticipada con morfologías muy diferentes. A su vez, estas nuevas conformaciones de pequeñas virutas, no son extraídas de la misma manera que las virutas largas flexibles y continuas, las cuales avanzan por propio impulso dentro del helicoides de la broca hasta el exterior del orificio prácticamente sin sufrir quebramiento alguno. Por el contrario las pequeñas virutas se fracturan y acumulan progresivamente adentro del helicoides o flauta hasta que alcanzan el exterior del agujero por rebalsamiento, lo que implica que el material está durante mucho más tiempo en contacto con la herramienta. Como consecuencia de lo anterior, la EA producida se ve modificada por la introducción de otros procesos que son fuentes de ondas elásticas relacionadas de manera indirecta con la condición de corte. En la Fig. 5.7 se muestra el material extraído durante el proceso de corte con diferentes condiciones de broca, donde se puede detallar la variedad de formas y longitudes de las virutas, propias de cada condición. Prosiguiendo el análisis de las diferentes condiciones de broca, se observa que solo algunas de ellas pueden ser reconocidas por cada parámetro, no existiendo uno único con capacidad de diferenciar claramente todas las condiciones en simultáneo. Esto puede verse reflejado en la evolución del RMS (Fig.5.6 d) donde se distingue la condición BA y se confunden los casos CM, CE y EG, limitación también visible en la PM (Fig. 5.6 b) donde los casos de EG son identificables respecto al resto de las condiciones que no pueden ser diferenciadas entre sí. Este tipo de comportamiento se reproduce para los demás parámetros.

De manera general, se puede determinar que solamente algunos parámetros de la EA clasifican una específica condición de deterioro y en ningún caso pueden discriminar en forma clara todas las condiciones de manera simultánea, aunque la condición de broca N es la que consecutivamente obtiene valores más bajos para todos los parámetros considerados.

A continuación se realizó el análisis de los mismos parámetros anteriormente estudiados, pero ahora los mismos se representan conjuntamente con su varianza (Fig. 5.7). El objetivo principal de esta metodología es poder hacer una estratificación de la información ya que por ser la varianza el cuadrado de la desviación estándar, se maximizan las grandes diferencias respecto de las pequeñas. Del comportamiento de los valores medios y sus varianzas asociadas, lo primero que se observa es que los casos N son los que poseen una varianza inferior con respecto a las demás condiciones de broca. Tanto la FA como los parámetros de EA muestran este comportamiento respecto a las brocas con óptimo estado

del filo. En general estos parámetros asocian una varianza pequeña a la condición N y una mucha mayor al resto de los casos con deterioro, siendo este comportamiento esperable en base a los fenómenos anteriormente explicados. También se puede observar que los casos de brocas con CM y CE presentan los valores de varianza más altos para los parámetros AMP, PM, RMS, y E.ABS y ocasionalmente variando para la FM y FA. Para este último parámetro, los casos CE tienen una varianza altamente inferior respecto la condición CM, lo que hace distinguibles a estos dos tipos de fillos modificados que son aparentemente muy similares para la varianza de los parámetros de la EA.

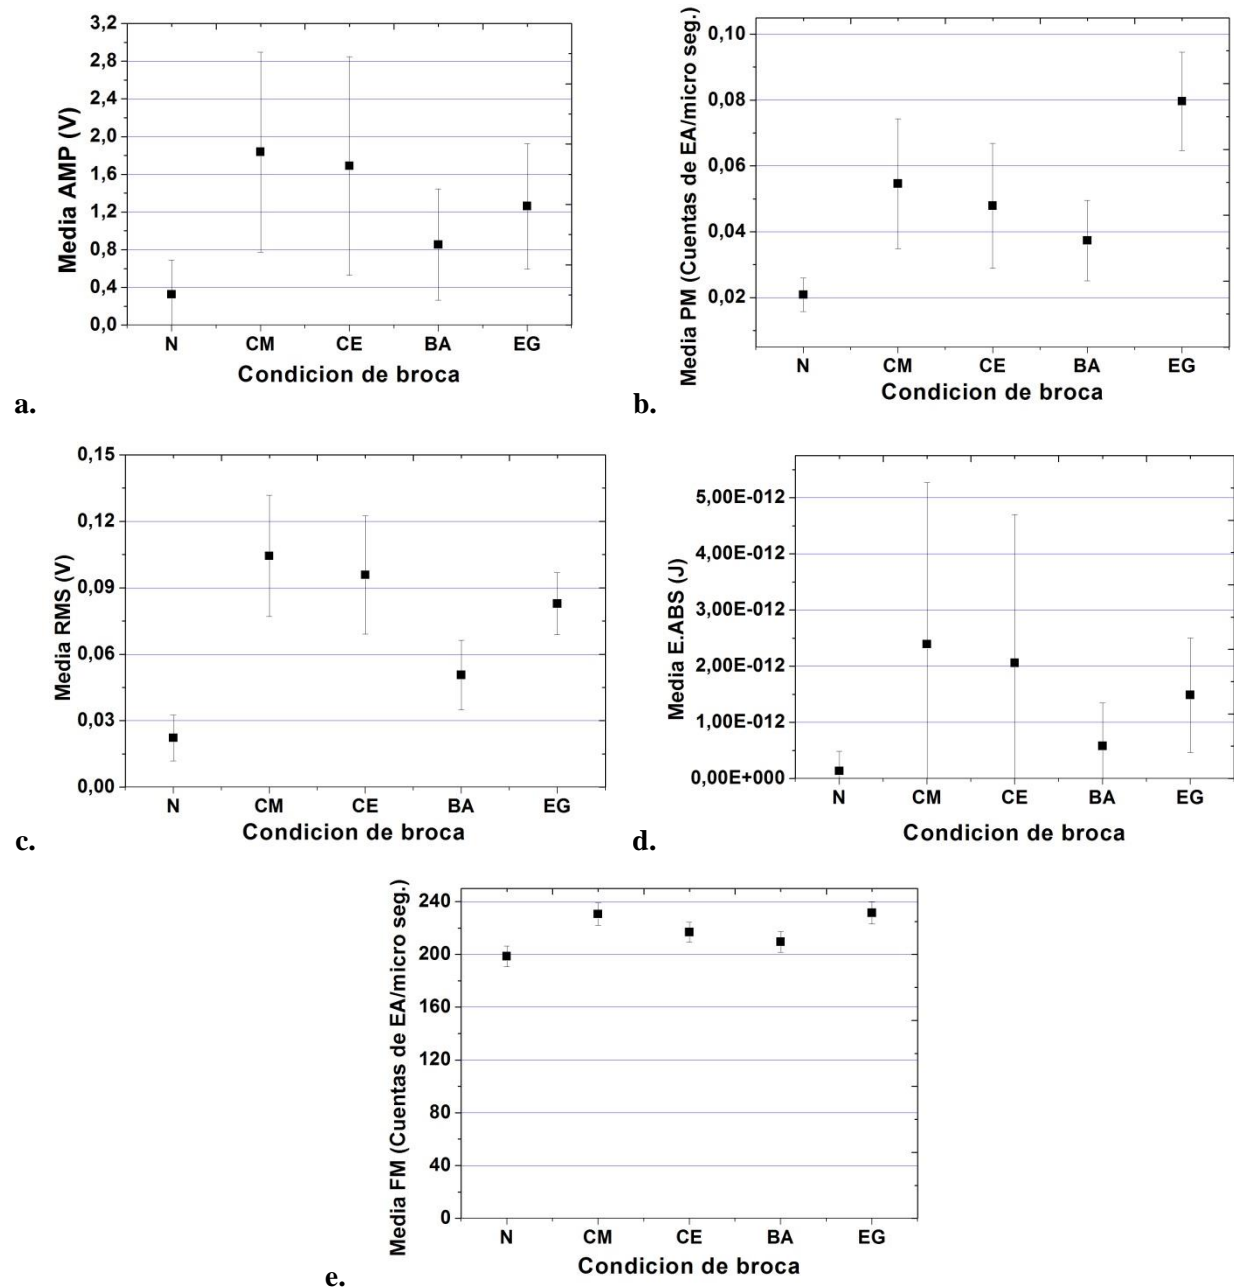


Fig. 5.6 Parámetros de EA respecto las diferentes condiciones de broca estudiadas.




Fig. 5.7 Fotografías de las virutas generadas para cada condición de broca. **a.** N. **b.** CM. **c.** CE. **d.** BA. **e.** EG.

Además, se observa que aun entre casos de brocas con iguales condiciones, existe una amplia dispersión de los valores de varianza considerados, lo que denota nuevamente la aleatoriedad del proceso que se está evaluando. Los que presentan mayor variación son los que contienen craterización en las caras de ataque y flanco de la herramienta. Los gráficos que representan estas situaciones, se encuentran en el Apéndice A8 donde se detalla la varianza de cada parámetro y para cada ensayo en particular.

De manera general se puede concluir que a simple vista es difícil reconocer un patrón que permita clasificar los diferentes casos de broca de manera satisfactoria, eventualmente son distinguibles los casos de CM y CE con cierta semejanza entre si y siendo la condición N la más claramente distinguible por todos los parámetros.

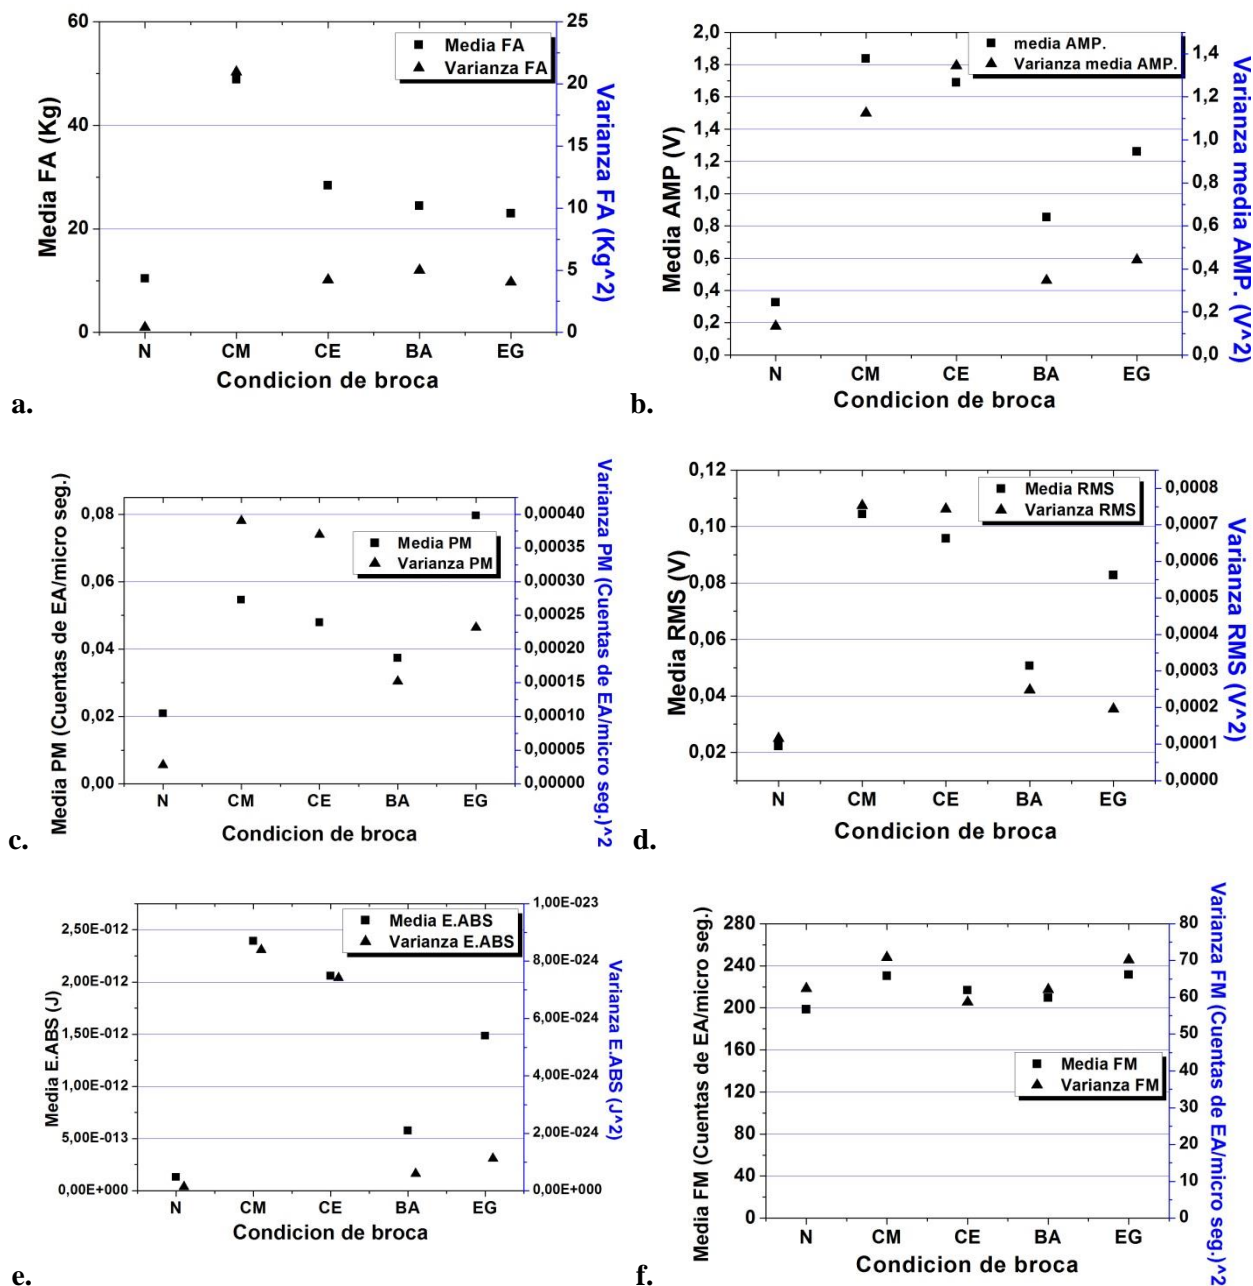


Fig. 5.7 Valores medios de los parámetros de EA con respecto a su Varianza para todos los ensayos realizados. a. FA. b. AMP. c. PM. d. RMS. e. EABS. f. FM

5.5 Estudio de la correlación entre EA y PM

En base a investigaciones realizadas en trabajos anteriores [Gómez (2012)] donde quedo establecida una correlación entre los valores de TQ y PM para el proceso de taladrado, se procedió entonces, a realizar una similar comparación para observar el comportamiento de la PM respecto a la FA. Para esto se realizó un análisis de correlación lineal entre todos los valores de la FA para las cinco condiciones respecto de los valores de PM. El resultado final indica que la correlación es inferior al 29 %. Esto puede observarse en la Fig. 5.8 a que indican que estos dos parámetros no varían de manera similar ante los diferentes casos de deterioro. En forma comparativa se muestran en la Fig. 5.8 b los resultados obtenidos para el TQ con respecto a la PM, donde se observa la alta correlación para todos los estados de broca estudiados.

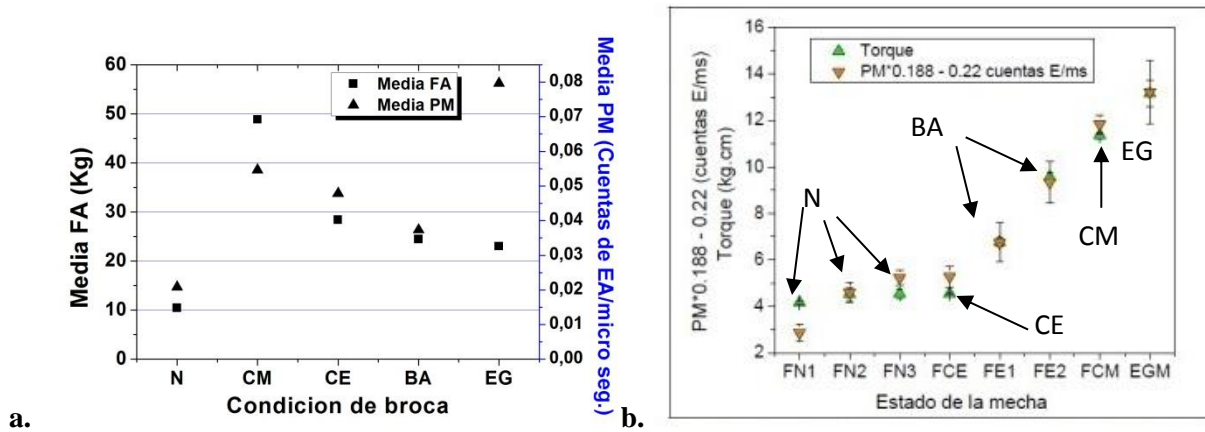


Fig. 5.8. Correlación entre parámetros: a. FA y PM. b. TQ y PM (Gómez 2012)

5.6 Análisis de la varianza respecto los valores medios de los parámetros de EA y FA

En general, para todos los parámetros evaluados hasta el momento, se puede observar que existe una variada dispersión de los valores medios, desviaciones estándar y varianzas. Esta dispersión puede ser muy grande o pequeña según los casos evaluados pero más que tomarla como una dificultad, puede ser tomada como distintiva a la hora de evaluar la condición de la broca como se señalará a continuación.

En la Fig. 5.9 se muestra la varianza en función de los valores medios para cada parámetro y condición de broca. En las Fig. 5.9. a y b, correspondientes a la FA y FM, no se observa una clara separación de la información ya que los casos CE, EG y BA se encuentran aglomerados en un caso y directamente encimados para la FM, no pudiéndose apreciar variaciones sujetas a las condiciones de las brocas o a los diferentes mecanismos de EA asociados a ellas. Sin embargo, si se consideran los parámetros RMS, E.ABS, AMP y PM, en la Fig. 5.9 c, d, e y f respectivamente se observa que discretizan la información separando más espaciadamente los casos de brocas N, BA, CE y CM. Al igual que en casos anteriores, se puede apreciar que los casos CE y CM aparecen asociados a los mayores valores de varianza, lo que habla de la variabilidad e inestabilidad que provocan estas condiciones de deterioro del filo durante el proceso de taladrado. Se corroboran también los resultados obtenidos por [Gómez y otros (2012)] donde se observa que para el parámetro PM, se hacen claramente distinguibles los casos de EG, ya que se posicionan en un sector del plano separados de los demás casos de deterioro en los filos de corte. Estos resultados marcan una diferencia a la hora de clasificar los casos de desgaste mostrando tres comportamientos bien diferenciados, por un lado filos en estado óptimos de corte (Nuevos), donde la fricción es baja así como la deformación plástica y el proceso de corte es estable y más regular que el resto de las condiciones. Seguidamente se encuentran los casos que involucran un daño en el filo de corte, haciendo que las condiciones en las que se desarrolla el corte del material sean mucho más inestables. Existe un aumento de la deformación plástica que hace que aumente la FA en todos los casos con respecto a los filos en estado N. Estas condiciones también producen una rotura excesiva e irregular de la viruta lo que resulta en una mayor cantidad y variabilidad de la EA. Estos casos se ordenan de manera creciente en las Fig. 5.9 c, d, e. A continuación, en la Fig. 5.9 f (Varianza PM vs. Valor medio de la PM) se puede observar un comportamiento semejante a una ley potencial desde los casos N hasta los de CE, distinguiendo claramente el caso de EG, separado de las condiciones anteriores. El proceso de taladrado en este estado involucra una alta componente de fricción entre las paredes del orificio y los extremos de los filos principales y auxiliares de corte, ya que la punta de la herramienta no perfora al material con el diámetro correcto como para que el resto del cuerpo de la broca avance libremente.

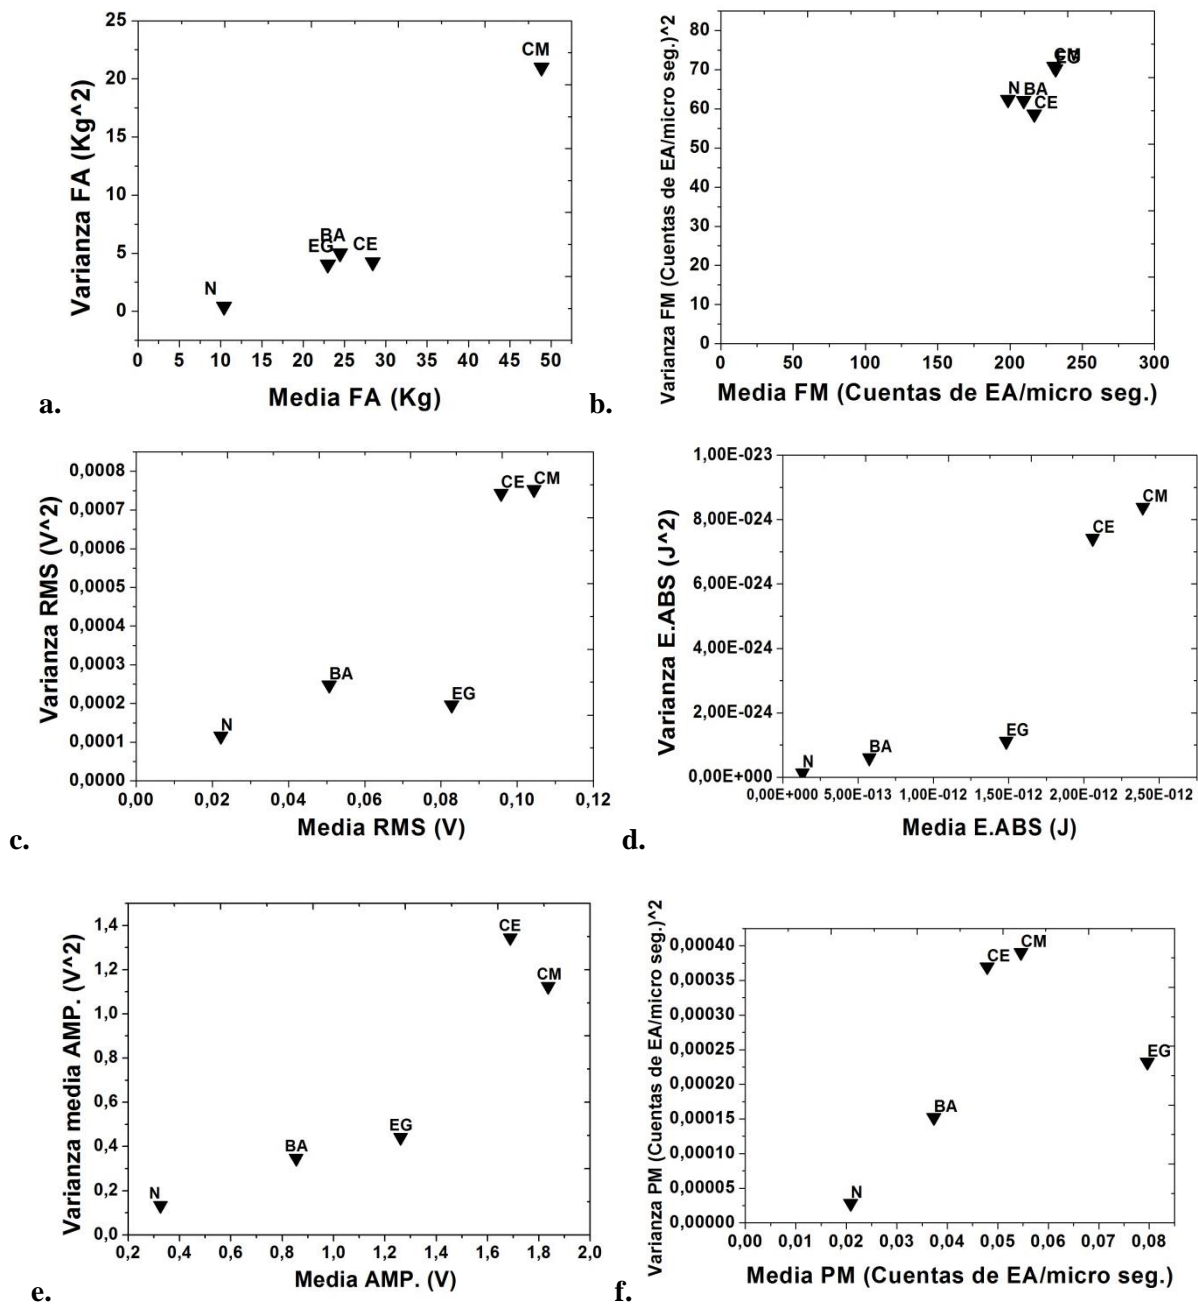


Fig. 5.9 Varianza vs. valor medio de los parámetros de EA para cada condición de broca. a. FM. b. AMP. c. RMS. d. EABS. e. FM.

5.7 ANÁLISIS POR COMPONENTES PRINCIPALES

La metodología de análisis de CP implica que se debe evaluar la cantidad de varianza que encierra cada CP. Del cálculo de captura de varianza, se obtuvo que el primer Componente Principal (CP1) captura aproximadamente un 60 %, el CP2 un 20 % y el CP3 solamente un 10 %. Esto puede ser observado en la Fig. 5.10 donde se detallan los porcentajes para los primeros 5 CPs. En base a estos valores se graficó toda la información en estos nuevos ejes de coordenadas, CP1 respecto CP2 (por capturar un 80 % de la varianza total entre ambos). En la Fig. 5.11 a se observa la distribución de los datos escalados mediante el método de autoescalado y en la Fig. 5.11 b los mismos datos escalados mediante minimax.




Fig. 5.10 Porcentaje de captura de Varianza de cada CP.

En los gráficos de CP mostrados en las Fig. 5.11, 5.12 y 5.13 se pueden observar cinco colores que identifican a los datos que corresponden a una misma condición de broca. En la Tabla 5.2 se brindan las referencias correspondientes. Los cinco clústeres se presentan compactos y con poca mezcla. Esto indicaría que cada condición tiene una varianza característica, pero son muy similares entre condiciones. Los datos pertenecientes a la matriz escalada mediante minimax (0-1) es el que da mejores resultados para el lote de datos estudiado. Las zonas de interfaz entre las nubes de puntos resultan ser más claramente separadas para los casos de brocas N (rojo) y CM (verde). Sin embargo, para los casos CE, BA y EG se forma una nube compacta en la cual se pueden distinguir las zonas mediante la coloración que se imprimió con el objetivo de identificar los datos, y no porque exista una separación espacial apreciable entre estos clústeres de datos.

En base a lo descripto previamente, se agregó un nuevo grado de libertad a la información existente, incluyendo un tercer eje ortogonal (CP3) y realizando un gráfico 3D. La sumatoria total de varianza, considerando el aporte de CP3, es del 90 % aproximadamente. El aporte de varianza de este último CP es cercano al 10 % sin embargo la contribución más importante que realiza es transformar las nubes de puntos hasta ahora planas en figuras de volumen, lo que facilita observar la distribución espacial de los datos. A continuación (Fig. 5.11) muestra las diferentes vistas de la distribución espacial de los clústeres de información para las dos matrices diferentemente escaladas.

De las comparaciones realizadas entre las figuras para cada escalado, se verifica que los datos escalados mediante el método minimax pueden identificar claramente tres clústeres de información separándolos entre sí. Estos corresponden a brocas con las condiciones N, CM y un tercer grupo compuesto por los casos CE, BA, y EG, que permanecen como un agrupamiento compacto que este método lineal no puede resolver. Este último grupo de casos está situado entre medio de dos condiciones de filo de brocas muy

diferentes entre sí. El análisis de componentes principales llevado a cabo es simple desde el punto de vista procedimental y de relativa economía de cálculo. Si se piensa en implementarlo en una PC para control y clasificación en línea del estado de la herramienta. Por otro lado, la dificultad de implementar el análisis y la evaluación visual de la información en un ambiente industrial puede inducir al operador a una interpretación equivocada. La mayor dificultad de observación de este método gráfico consiste en que según qué plano de vista se decida cortar, la información puede encontrarse solapada o no, teniendo que considerar varias vistas de la distribución espacial de los datos para juzgar la posición relativa de la información. Además en el caso de obtener nuevos datos en línea de la condición de corte de una herramienta, habría que incluirla en el modelo y comenzar a “buscar” la posición de estos nuevos datos dentro de una figura 3D, para luego por ejemplo a través del cálculo de distancias, poder identificar su grupo de pertenencia.

Tabla 5.2 Condición de broca y color de identificación en gráficos CP.

ESTADO DE LA BROCA	
<i>Nuevas [N]</i>	
<i>Cráter Mecánico [CM]</i>	
<i>Cráter Electro Erosión CE]</i>	
<i>Broca Achaflanada [BA]</i>	
<i>Esquina Gastada [EG]</i>	

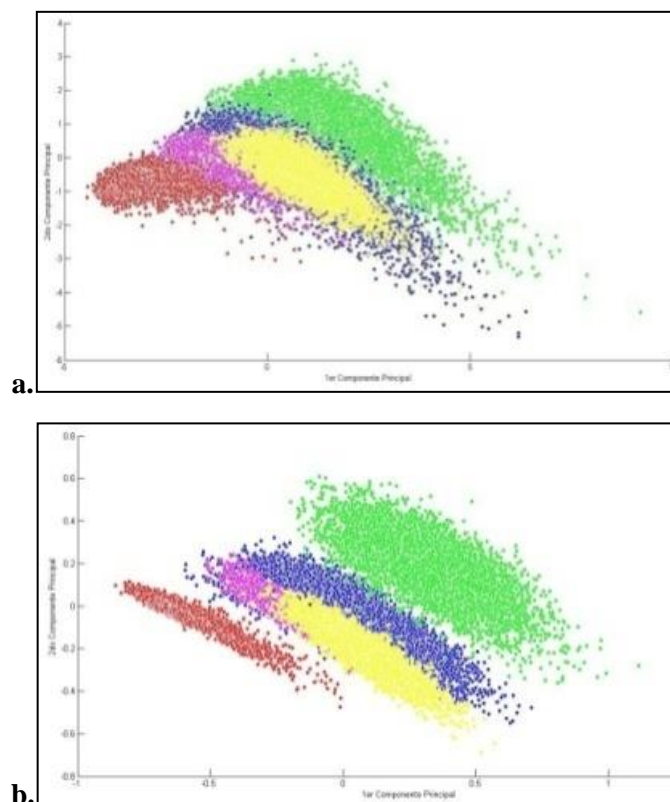


Fig. 5.11 CP1 vs CP2, **a.** para datos autoescalados. **b.** Para datos escalados minimax.










Fig. 5.12 a, b y c. Tres vistas diferentes de los clúster de información autoescalados.






Fig. 5.13 a, b, c, d y e. Cinco diferentes vistas de los clústeres de información escalados mediante minimax.

En base a lo argumentado anteriormente y considerando la posibilidad de que el comportamiento entre algunas de las variables estudiadas sea no lineal, se derivó en la utilización de otro método de clasificación de señales que tiene la capacidad de modelizar información de característica no lineal y que expresa los resultados de manera clara. Para esto se utilizará una red neuronal tipo SOM.

5.8 Análisis por Redes Neuronales tipo Mapa Auto Organizado - Kohonen

5.8.1 Resultado del entrenamiento

El tamaño de las sub matrices utilizadas en los entrenamientos de la red afectó directamente el tiempo de cálculo. A modo de ejemplo, el tiempo de cálculo promedio para una sub matriz de dimensión de 1000 x 8, fue de 43 segundos por época (utilizando una computadora con procesador i7 y 8 Gb de memoria RAM). Con 500 épocas, el tiempo de entrenamiento totalizó aproximadamente 6 horas de procesamiento. Para una sub matriz 1500 x 8 el tiempo de procesamiento en igualdad de condiciones fue de 77 s para una época, totalizando el entrenamiento 10,7 horas. Mediante estos datos empíricos se puede comprender la conveniencia de encontrar las combinaciones de variables (cantidad de parámetros, épocas, factores de ajuste, etc.) que hagan que la red trabaje de manera más eficiente y que se llegue en el menor tiempo posible a determinar una arquitectura con un buen grado de acierto en la modelización.

Para evaluar el progreso de las diferentes arquitecturas de entrenamiento hacia una mejora en los resultados de clasificación se analizan los porcentajes de error obtenidos con cada configuración probada. La Fig. 5.14 detalla el progreso de los valores de error para los últimos 12 entrenamientos realizados con sub matrices de variadas dimensiones. El detalle de la configuración de la red y los valores de los factores de ajuste que se usaron en cada arquitectura se encuentran especificados en la Tabla 5.3.

Tabla 5.3 Detalle de las configuraciones utilizadas durante el entrenamiento de la red neuronal.

Config.	Tamaño de Red	Geom.	Función de corrección	Tamaño de Vecindad	Corrección de pesos			Época	Máx. valor absoluto de pesos	Tamaño de sub matriz
					Max.	Min	Tipo			
1	40 x 40	Planar	Triangular	15	0.9	0.05	V y E	500	0.0001	1000 x 8
2	40 x 40	Planar	Gausiana	15	0.9	0.1	V	500	0.0001	1000 x 8
3	40 x 40	Planar	Gausiana	15	0.9	0.1	V	500	0.0001	1000 x 8
4	40 x 40	Planar	Gausiana	15	0.9	0.05	V y E	500	0.001	1000 x 8
5	40 x 40	Planar	Gausiana	11	0.7	0.1	V	500	0.01	1000 x 8
6	40 x 40	Toroidal	Gausiana	11	0.7	0.1	V	500	0.01	1000 x 8
7	40 x 40	Planar	Gausiana	11	0.7	0.1	V y E	1000	0.01	1000 x 8
8	40 x 40	Toroidal	Gausiana	11	0.7	0.1	V y E	1000	0.01	1000 x 8
9	40 x 40	Planar	Gausiana	5	0.7	0.1	V y E	500	0.01	1000 x 8
10	40 x 40	Toroidal	Gausiana	5	0.5	0.1	V y E	500	0.01	1000 x 8
11	50 x 50	Planar	Gausiana	17	0.9	0.1	V y E	500	0.0001	1000 x 8
12	50 x 50	Planar	Gausiana	17	0.6	0.1	V y E	500	0.0001	1500 x 8

V y E: Por vector y por Época, V: Por Vector solamente.




Fig. 5.14 Evolución de los errores para los 12 últimos entrenamientos.

Esta serie de entrenamientos corresponden a las configuraciones de red más refinadas y con menor porcentaje de error. Como se puede observar, todas clasifican con un error de mezclado inferior al 10 % y un error de norma menor que 0.025. Para todos los casos se definió que la regla de aprendizaje competitivo utilizada para la neurona ganadora sería aquella cuyo *peso sea más similar al vector de entrada*. Este fue el único parámetro que no sufrió modificaciones en los sucesivos entrenamientos. La dimensión de las sub matrices utilizadas variaron desde (500 x 8) a (1500 x 8) vectores dato. En los casos 1-10 la dimensión de la red es de 1600 neuronas (40 x 40) y en los casos 11 y 12 la cantidad de neuronas se extendió a 2500 (50 x 50). En forma simultánea, se procedió variando el resto de los parámetros de arquitectura como la cantidad de vecinos, factores de corrección de los pesos y valores iniciales de los mismos. Finalmente se puede observar que las arquitecturas pertenecientes a los entrenamientos número 11 y 12 son los que obtienen mejores resultados considerando los dos tipos de errores. En la Tabla 5.3 se detalla su configuración.

La diferencia más apreciable entre los dos entrenamientos es el tamaño de la sub-matriz de información que se le presentó a la red. Para el caso 11 fue de dimensión 1000 x 8 mientras que en el caso 12 fue de 1500 x 8. Otro factor que diferenció las dos configuraciones es el ajuste realizado para las máximas correcciones de los pesos, el cual en un caso fue de 0.9 (alto) y en el otro de 0.6 (intermedio). La arquitectura 12 mostró bastante oscilación de los valores de error antes de comenzar a converger hacia valores menores. Esto puede ser atribuido a una mayor variedad de datos contenidos en la sub-matriz. Un factor de corrección fuerte hace que la convergencia de la red (si existe) sea más rápida. Pero si los valores que entran a la red tienen variaciones amplias, correcciones altas provocan que los pesos oscilen demasiado dificultando la convergencia de la red hacia un mapa de pesos similar a los datos de entrada. Los valores de error para los dos entrenamientos respectivos se muestran en la Tabla 5.4. En ambos casos el error de mezclado está por debajo del 5 % lo que se considera aceptable y el error de norma es pequeño. A pesar de ello el error verdadero de estos mapas de entrenamiento deberá ser evaluado en la predicción, donde se espera que los resultados sean mayores que los actuales pero inferiores al límite establecido del 5 %.

Tabla 5.4 Valores de error para entrenamientos 11 y 12.

	ENTRENAMIENTO 11	ENTRENAMIENTO 12
Error de Mezclado	2.5 %	0.5 %
Error de Norma	0,008386	0.017016

Los mapas resultantes de los entrenamientos para los casos 11 y 12 se representan en las Fig. 5.15. y 5.16 respectivamente. En la Tabla 5.5 se individualiza el código de colores utilizado para identificar los diferentes grupos de clasificación.

Sobre los mapas, se pueden visualizar 5 zonas topológicas diferentemente coloreadas que corresponden a las 5 condiciones de ensayo realizadas. Las zonas que más fácilmente pueden ser identificadas pertenecen a los casos de brocas N, CM para los dos mapas. Seguidamente la condición de EG y luego los casos de CE y BA, estos últimos dos casos comparten una gran frontera en común y la separación no es tan clara como en lo grupos anteriores, más se encuentra satisfactoriamente definida.

Tabla 5.5 Código de colores para clasificación de condición de broca sobre los mapas topológicos.

Color y Estado de la Broca

Nuevas [N]
Cráter Mecánico [CM]
Cráter Electro Erosión [CE]
Broca Achaflanada [BA]
Esquina Gastada [EG]




Fig. 5.15 Mapa de entrenamiento perteneciente a la red 11.




Fig. 5.16 Mapa de entrenamiento perteneciente red 12.

En forma detallada se nota la existencia de ciertas zonas donde la pertenencia de la información no está del todo resuelta. Dichas regiones se marcan de manera esquemática en la Fig. 5.17 donde en el caso (a) se encuentran involucradas las condiciones BA y EG en un lado y BA-CE-CM por otro. Luego en el mapa de la Fig. 5.17 b las zonas de mezcla contienen los casos CE-BA principalmente y eventualmente algunos casos EG. En ambos mapas existen algunas neuronas activadas erróneamente muy dentro de las zonas de clasificación de un grupo. Estas fueron activadas por datos que son considerados atípicos (outliers) que además por ser escasos no repercuten de manera importante en la eficiencia de clasificación.

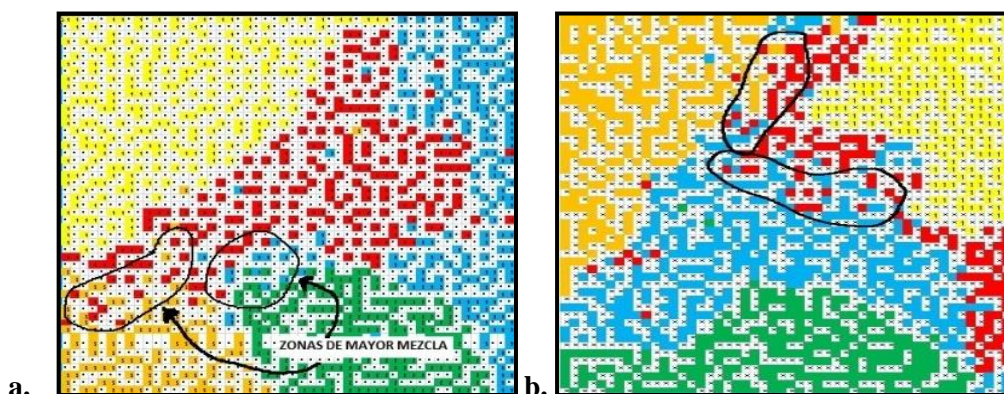


Fig. 5.17 Demarcación de zonas de confusión más importantes.

Para corroborar la información de la inspección visual y evaluar qué tipo de condiciones confundió la red, se llevó a cabo un control de los datos que han sido mal clasificados por la red. Para este análisis, se comparan los datos que activaron una misma neurona de la red y se evalúan sus etiquetas identificadoras. En el caso del entrenamiento con la arquitectura 12 los errores de mezclado se resumieron en la Tabla 5.6 que detalla la posición de la neurona en el plano con notación alfanumérica de fila y columna (row, column) y a continuación el número identificador de los datos (una de las dos variables adicionales cargadas a la matriz original) que fueron colocados en ese casillero. Se puede observar que salvo el último valor de la lista, el resto pertenecen a las series 510000 y 520000 que son los códigos (etiquetas identificadoras) de los ensayos pertenecientes a las condiciones de broca CE y BA respectivamente. Luego los códigos de los vectores dato pertenecientes a la serie 53000 corresponden a los casos de EG.

Tabla 5.6 Control de error de mezclado para el entrenamiento 12.

POSICIÓN DE LA NEURONA	VECTOR DATO 1	VECTOR DATO 2
R1 c33	522548	512778
R18 c29	521286	510751
R19 c20	522902	513076
R20c23	510316	521841
R23 c23	521042	512907
R29 c40	522958	515262
R37 c45	521226	515639
R11 c22	522454	530175

Desde el punto de vista topológico de la información los casos de bocas N con filos agudos y sin desgaste apreciable se posicionan lejos de los casos CM que corresponden a una de las condiciones de filo con más deterioro. Eventualmente el resto de los casos con filos en diferentes condiciones de desgaste se acomodan entre medio de estos dos casos extremos. Sobresaliendo la condición de EG respecto CE y BA.

Antes de avanzar a la etapa de predicción, se realizó un análisis adicional con el objetivo de evaluar la importancia relativa de los parámetros de EA y la FA respecto al proceso de entrenamiento. Para esto se modificó la programación de la red neuronal de manera que al finalizar cada época de entrenamiento se genere un archivo con los valores parciales de errores de mezclado y de norma. A continuación se llevaron a cabo seis entrenamientos adicionales con sub matrices de dimensión de 1000 x 7. A estas matrices se les sustrajo sistemáticamente uno de los seis parámetros que describen la medición, dejando fijos los dos parámetros identificadores. Luego, en base a la configuración de la arquitectura 11 se corrieron los seis entrenamientos para comparar los valores finales de error con respecto al parámetro faltante. A cada sub matriz se le asignó un nombre donde el parámetro presente se enumeró con un 1 y al parámetro extraído se le asignó un 0. De esta manera, dado que el vector de datos está compuesto de como: $[FA - FM - AMP - RMS - EABS - PM]$, si se extrae el parámetro FA, el nombre de la matriz quedará determinado como 011111. Con estas modificaciones en la programación y en las sub matrices de entrenamiento se pudieron ver de qué manera converge más rápido la red y cuál es el valor final de error al sustraerle un parámetro determinado.

Los resultados mostrados en las Fig. 5.18 y Fig. 5.19 indican la evolución de los errores en función de las épocas de procesamiento para los seis entrenamientos realizados. Analizando la Fig. 5.18 que muestra el progreso del error de mezcla, se observa que la convergencia de la red al eliminar la FA es mucho más lenta que al suprimir los demás parámetros. Adicionalmente el valor final de error obtenido es de 3,4 % mientras que para los restantes entrenamientos es menor al 1 %. Esto indica que la información que aporta la FA es relevante a la hora de diferenciar los casos de desgaste, ya que ayuda a la red a precisar más rápidamente la información, eventualmente acortando el período de épocas de entrenamiento.

En la Fig. 5.19 se representa el progreso del error de norma. Si bien la AMP y PM son los parámetros que convergen con más lentitud, no muestran variaciones sustanciales con respecto a los entrenamientos

realizados extrayendo las demás variables. Los valores finales de error de norma a los que llegan todos los entrenamientos son muy bajos y similares entre sí.




Fig. 5.18 Evolución del error de mezclado en función de las épocas de procesamiento.




Fig. 5.19 Evolución del error de norma en función de las épocas de procesamiento.

5.8.2 Resultados de la Predicción

La siguiente sección brinda los resultados correspondientes a las predicciones realizadas al alimentar la red con diferentes sub matrices, utilizando los mapas de pesos calculados en los entrenamientos números. 11 y 12. Los tamaños de las sub matrices y la cantidad de cada una de ellas seleccionadas para predicción, se detallan en la Tabla 4.5 del Capítulo 4. Como se especificó en la introducción, el proceso de predicción es muy corto en comparación con el de entrenamiento. El mismo solo tarda algunos segundos debido a que los valores de todos los pesos ya están calculados en el proceso de entrenamiento. Aquí solamente se debe evaluar que peso asociado a una neurona es más similar al vector de entrada. Luego, la neurona ganadora se marca en el mapa y así sucesivamente se evalúan todos los vectores de información de las sub matrices. Primeramente se observarán los porcentajes de error de las simulaciones y luego se evaluará la distribución espacial de los datos sobre el mapa de predicción.

En la Fig. 5.20 y Fig. 5.21 se detalla el progreso de los errores de simulación para los mapas con entrenamientos 11 y 12 respectivamente. Los casos de predicción están ordenados de menor a mayor tamaño en función de la sub matriz simulada.




Fig. 5.20 Evolución del error de mezclado y de norma para la simulación en arquitectura 11.

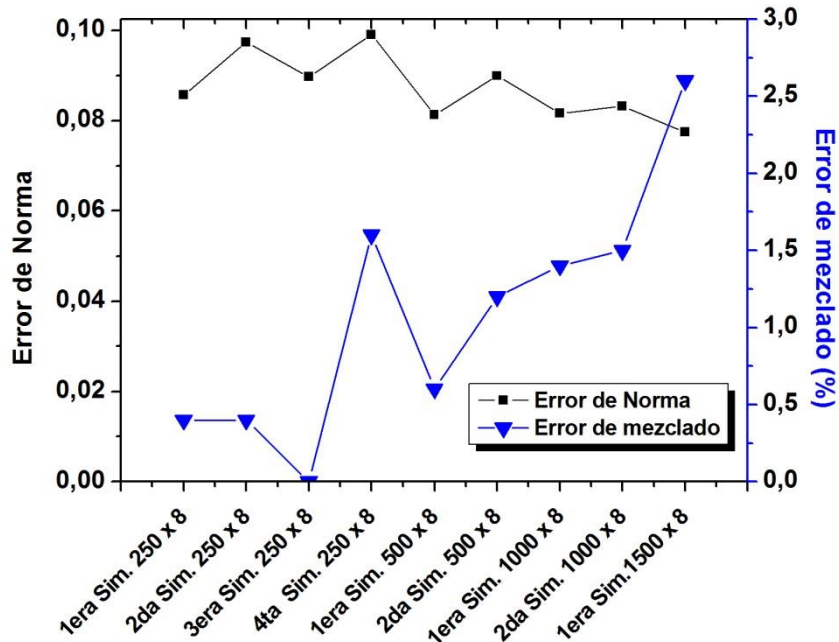


Fig. 5.21 Evolución del error de mezclado y de norma para la simulación en arquitectura 12.

El comportamiento de ambas redes resultó similar, logrando clasificar la información con un resultado de error satisfactorio. Se obtuvieron valores por debajo del 5 % para el error de mezclado y errores de norma algo mayores que en el entrenamiento (lo que era esperado) pero igualmente aceptables. Se observa además que el error de norma para los dos casos disminuye y se estabiliza a medida que se aumenta la cantidad de datos con los que se realiza la predicción. Si consideramos que el error de norma es un valor promedio de la distancia de los pesos de cada neurona ganadora con respecto al valor de entrada (vector dato), entonces se puede pensar que al tener una sub matriz de mayor tamaño estamos promediando sobre una población más amplia. Esta es a su vez más representativa de la matriz original de datos y por lo tanto posiblemente más similar en su comportamiento al lote de datos utilizado para el entrenamiento. Es importante observar que también las predicciones hechas con sub-matrices de tamaños comparables y mayores a las sub matrices de entrenamiento dieron valores de error bajos, lo que habla de la buena representatividad de la cantidad y calidad de los datos extraídos para entrenamiento. Si por otra parte analizamos la evolución de los errores de mezclado se observa que existe una tendencia a aumentar con el

creciente tamaño de la sub matriz considerada. Este comportamiento es posible atribuirlo a que las sub matrices de reducidas dimensiones representan un espacio muestral más pequeño y con menor variedad de casos posibles, es decir, es más dificultoso que existan dos o más vectores de información tan similares que den como resultado la activación de la misma neurona mientras que en los lotes de mayor tamaño esto puede ser más probable.

En las Fig. 5.22 y 5.27, para las configuraciones 11 y 12 respectivamente, se muestran los mapas correspondientes a los entrenamientos con las zonas limítrofes de pertenencia demarcadas para cada grupo. A continuación de estas se muestran los mapas de las predicciones, para la configuración 11 en las Fig. 5.23, 5.24, 5.25, 5.26 y para la configuración 12 en las Fig. 5.28, 5.29, 5.30 y 5.31 ordenados de menor a mayor tamaño de sub matriz simulada.




Fig. 5.22 Mapa de entrenamiento para configuración 11.

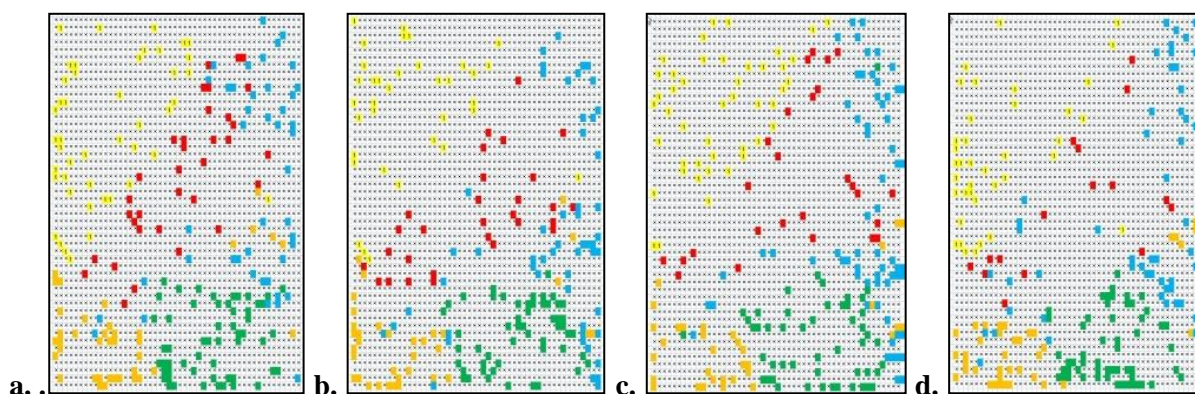


Fig. 5.23 Mapas de simulación para configuración 11 con sub matriz 250 x 8. a. Simulación 1. b. Simulación 2. c. Simulación 3. d. Simulación 4.




Fig. 5.24 Mapas de simulación para configuración 11 con sub matriz 500 x 8. **a.** Simulación 1. **b.** Simulación 2.




Fig. 5.25 Mapas de simulación para configuración 11 con sub matriz 1000 x 8. **a.** Predicción 1. **b.** Predicción 2.




Fig. 5.26 Mapa de simulación para configuración 11 con sub matriz 1500 x 8. Predicción 1

En la Fig. 5.23 correspondiente a las cuatro sub matrices de menor tamaño (250 x 8 vectores) se puede observar que los casos N y CM son claramente identificables en zonas correctamente delimitadas y opuestas del mapa. Luego la condición de EG forma una zona relativamente compacta con algunos casos pertenecientes a otras condiciones de broca en el interior de su zona. A su vez algunos otros casos de EG se encuentran más alejados de la región de pertenencia delimitada, estos se pueden apreciar en la parte

central derecha de estos mapas. Con respecto a las condiciones CE y BA la mayoría de los casos caen dentro de su zona de pertenencia, mientras que el resto de los casos no podrían clasificarse a simple vista dado que la separación entre estas dos regiones no es clara. Esto se debe en parte a que los límites no se encuentran prolijamente demarcados y son irregulares en comparación con las condiciones anteriores, dificultando así la delimitación de las fronteras. A pesar de ello se observa que eventualmente la red confunde algunos casos entre estas dos condiciones. Estos se pueden apreciar en la parte central del mapa representados en las Fig. 5.23 b, c, y d.

En los mapas de predicción (Fig. 5.24 y 5.25) que son simulaciones con sub matrices de tamaño 500/1000 x 8 vectores, se vuelven a repetir los patrones de confusión de los casos anteriores, pero magnificados. Esto es producto del proporcional aumento de casos erróneamente clasificados por la red, al aumentar la cantidad de vectores dato. Ahora bien, este aumento también trae un efecto beneficioso, que es el mejor delineamiento de las fronteras quedando regiones más claramente determinadas. En este punto del análisis es interesante remarcar dos aspectos. El primero pertenece a las zonas de casos mezclados de EG y CE los cuales aparecen siempre en el mismo sector del plano. Esta zona clasifica de manera consecuente la información perteneciente a los diferentes lotes de predicción. Es posible considerar que estos datos podrían tender a formar un sub grupo de información más pequeño con características semejantes. El segundo aspecto a considerar es que si bien las fronteras de las zonas pertenecientes a las condiciones BA y CE son las menos definidas y los casos parecieran ser los más mezclados es mayoritariamente la condición CE que invade la zona correspondiente a la condición BA: Se puede observar que los casos BA se encuentran razonablemente dentro de su región de pertenencia (para la gran mayoría de los casos) siendo muy pocos los puntos clasificados en otro lugar.

En base a lo anterior se puede considerar que esta red clasifica de manera precisa los casos N, CM y BA, y con menor exactitud lo hace para los casos EG. Por último y de forma variada clasifica los casos de CE. El último mapa perteneciente a la predicción con la sub matriz de mayor tamaño 1500 x 8, Fig. 5.26 muestra un comportamiento más acentuado de los patrones analizados anteriormente, es decir que las zonas de confusión se ven claramente y las regiones quedan mejor delimitadas debido al aumento de la cantidad de datos. Es importante remarcar aquí que esta matriz de predicción supera en un 50 % la dimensión de la sub matriz de entrenamiento y a pesar de ello logra un aceptable desempeño en el proceso de clasificación.




Fig. 3.27-Mapa de entrenamiento para configuración 12.

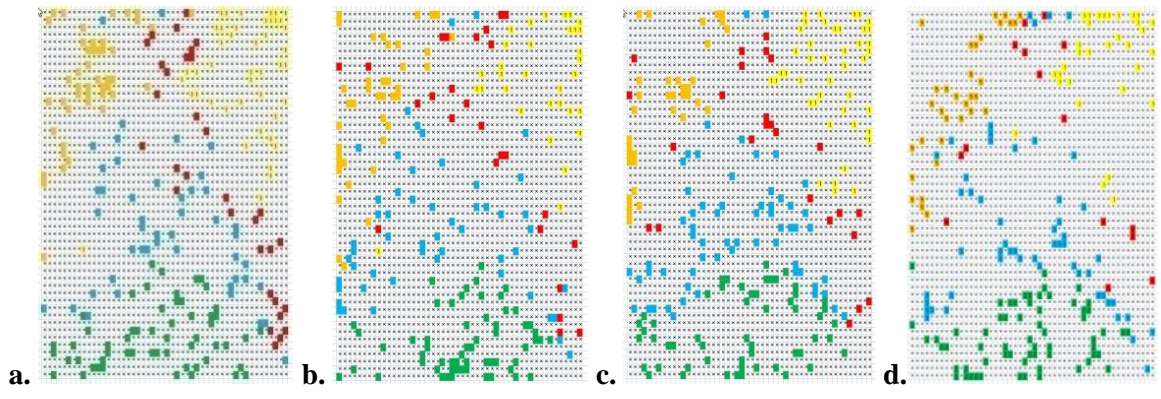


Fig. 5.28 Mapas de simulación para configuración 12 con sub matriz 250x8. **a.** Simulación 1. **b.** Simulación 2. **c.** Simulación 3. **d.** Simulación 4.




Fig. 5.29 Mapas de simulación para configuración 12 con sub matriz 500x8. **a.** Simulación 1. **b.** Simulación 2.




Fig. 5.30 Mapas de simulación para configuración 12 con sub matriz 1000x8. **a.** Simulación 1. **b.** Simulación 2.




Fig. 5.31 Mapa de simulación para configuración 12 con sub matriz 1500 x 8.

Realizando un análisis similar al anterior, en la Fig. 5.28 que representa a la simulación para las matrices 250 x 8 se puede distinguir que la arquitectura 12 clasifica de manera clara los casos N, CM y EG, en particular para la última condición y a diferencia de la arquitectura 11, no se presentan casos de EG en otro sector del plano sino que se encuentran todos agrupados razonablemente dentro de su región de pertenencia. Detallando las regiones correspondientes a los casos de CE y FA se muestra que la confusión de condiciones de broca es menor. Si bien sigue existiendo mezcla y los límites de las regiones son irregulares, se puede apreciar que los casos de CE invaden mucho menos las zonas aledañas y especialmente la región de BA. Esto se puede observar claramente en las simulaciones de las Fig. 5.30 y Fig. 5.31 que corresponden a las sub matrices 1000 y 1500 x 8 donde las zonas de clasificación se observan definidas por la amplia cantidad de puntos simulados.

Una comparación entre las arquitecturas 11 y 12 muestra que esta última parece clasificar más prolijamente y mejor los diferentes casos de desgaste, siendo los casos N, CM, EG, y BA satisfactoriamente reconocidos y en menor medida los casos correspondientes a CE.

De manera general, las dos arquitecturas clasificaron satisfactoriamente los casos presentados en las simulaciones, mostrando que estas redes tienen la capacidad de reconocer las 5 diferentes condiciones de brocas identificándolas en base a la información adquirida de forma indirecta en el proceso de taladrado por la EA y la FA. Adicionalmente, la información resultante es presentada de manera amigable y fácil de interpretar en mapas bidimensionales considerando que la información brindada corresponde a un sistema multivariable.

Capítulo 6

CONCLUSIONES

Los resultados del monitoreo indirecto mediante la EA y la medición de la FA de los ensayos sistemáticos de taladrado, sobre probetas de acero SAE 1040, para cinco brocas en diferentes condiciones de desgaste se exponen en la presente sección.

El parámetro FA resultó ser un muy útil indicador del estadio del proceso de corte, mediante este se pudieron identificar de manera precisa las diferentes etapas del proceso. Estas fases del proceso de taladrado fueron identificables en todos los ensayos de manera independiente respecto de la condición del filo de la broca estudiada.

Se observó que la broca con filo N aplica menos FA para realizar el orificio y que cualquier deterioro producido en los filos de la broca reflejará un incremento en este parámetro. Esto puede deberse a que una herramienta de geometría afilada produce un corte uniforme que genera una zona de deformación plástica reducida y muy focalizada en el plano de corte. En esta condición, la región de pre-flujo plástico es pequeña. Al introducir un defecto en los filos de corte, la deformación plástica que sufre el material tanto cortado como el que permanece aún sin cortar en la pieza es mucho mayor, por lo tanto la energía involucrada en el proceso de corte aumentará. Además los procesos friccionales relacionados con el contacto entre la cara y el flanco de la herramienta también se incrementarán según el tipo de defecto considerado

Para el proceso de taladrado y las diferentes condiciones de broca, se determina que la EA y la FA no tienen distribuciones exclusivamente normales para cada parámetro, en algunas combinaciones (parámetros y condiciones de broca) se obtienen comportamientos normales, Lognormales o ninguno de los dos. Únicamente el parámetro de *Energía Absoluta* obtuvo una distribución constante durante todos los ensayos, siendo la misma posiblemente de carácter Lognormal.

Para los diferentes parámetros de EA y FA existe diversa correlación lineal. Este valor se ve modificado de condición en condición, no pudiéndose establecer un patrón de comportamiento definido. Por lo tanto no se pudo reducir (en nuestro caso) el número de variables de medición para disminuir dimensionalmente el problema, porque en principio todas las variables aportan diferente información no linealmente correlacionada que puede ser utilizada para clasificar las condiciones de broca. Esto último va en desmedro de la eficiencia de cálculo.

No se evidenció correlación entre la PM y la FA como si quedo establecida en trabajos anteriores respecto de la PM y el TQ para el proceso de taladrado.

Los parámetros de EA y FA graficados para las diferentes condiciones en base a sus valores medios y desviación estándar no permiten una clara identificación de la condición de deterioro de la herramienta de taladrado. Estos solamente distinguen algunas condiciones específicas sobre otras dependiendo del parámetro seleccionado, pero en ningún caso lo hacen de manera simultánea para todas las condiciones abordadas. Sin embargo la condición de broca *Nueva* (N) mostro de manera consecutiva y para todos los parámetros de EA, los valores medios y desvíos más bajos en comparación con las demás brocas. Esto puede ser atribuido en parte a lo anteriormente explicado para la FA y al hecho de que cuando la geometría de la herramienta no contiene un desgaste considerable, produce que el material que se extrae lo haga manera continua. Este sale en forma continua con poca deformación plástica general y mucha deformación concentrada en el plano de corte, para luego ir curvándose y conformar virutas de largas dimensiones. Por el contrario un filo deteriorado produce mucha más deformación en la viruta, endureciendo el material, cambiando la geometría de salida del mismo y haciendo que se fracture de

forma anticipada con morfologías muy diferentes. A su vez, estas nuevas conformaciones de pequeñas virutas, no son extraídas de la misma manera que las virutas largas, flexibles y continuas, las cuales avanzan por propio impulso dentro del helicoide de la broca hasta el exterior del orificio prácticamente sin sufrir quebramiento alguno. Por el contrario las pequeñas virutas se fracturan y acumulan progresivamente adentro del helicoide de la broca hasta que alcanzan el exterior del agujero por acción de rebalse o acumulación, lo que implica que el material está durante mucho más tiempo en contacto con la herramienta e interactuando con ella. Como consecuencia de lo anterior, la EA producida se ve modificada por la introducción de otros procesos que son fuentes de ondas elásticas y que amplían el espectro de emisión produciendo efectos espurios y aumentando la dispersión.

Del comportamiento de los valores medios y sus varianzas asociadas, se observa que al igual que los casos anteriores, la condición N posee una varianza inferior con respecto a las demás condiciones de broca. Tanto la FA como los parámetros de EA muestran este comportamiento donde se asocia una varianza pequeña a la condición N y una mucha mayor al resto de los casos con deterioro. Del comportamiento de los valores medios y sus varianzas asociadas, se observa que los casos N son los que poseen una varianza inferior con respecto a las demás condiciones de broca. Tanto la FA como los parámetros de EA muestran este comportamiento respecto a las brocas con óptimo estado del filo. En general estos parámetros asocian una varianza pequeña a la condición N y una mucha mayor al resto de los casos con deterioro, siendo este comportamiento esperable en base a los fenómenos anteriormente explicados.

El análisis realizado en base al estudio de la varianza respecto del valor medio del parámetro considerado muestra de manera general una mejor separación de los casos de estudio. Específicamente si se analizan los parámetros RMS, E.ABS, AMP y PM se observa que se separan los casos de brocas N, BA, CE y CM respecto del resto. Además se puede apreciar que los casos CE y CM aparecen asociados a los mayores valores de varianza, lo que habla de la variabilidad e inestabilidad que provocan estas condiciones de deterioro del filo durante el proceso de taladrado. Se corroboran también los resultados obtenidos por [Gómez y otros (2012)] donde se observa que para el parámetro PM, se hacen claramente distinguibles los casos de EG, ya que se posicionan en un sector del plano separados de los demás casos de deterioro en los filos de corte.

Mediante el método de análisis por Componentes Principales se pudieron separar los casos de brocas N y CM. Sin embargo para los casos CE, BA y EG no se observó una separación espacial apreciable para estos clústeres de datos, siendo el escalado tipo minimax el que mostro los mejores resultados. A su vez la adición de un tercer CP a la representación permitió obtener gráficos en tres dimensiones, admitiendo diferentes vistas en la distribución de puntos, lo que mejora la separación pero genera el inconveniente de que la información puede ser mal interpretada según el plano de vista que se corte para visualizar. El resultado obtenido por el análisis de CP indicaría que la relación entre las variables de la EA (entre sí) y con respecto a la FA, es no lineal. Por lo tanto no sería posible, en base a este tipo de información, utilizar modelos lineales para describir este proceso en particular.

Los resultados obtenidos mediante la utilización de una Red Neuronal SOM – KOHONEN son satisfactorios. Esta permitió clasificar claramente 4 de las 5 condiciones de broca (N-CM-BA-EG), quedando solo una condición (CE) medianamente clasificada.

Las arquitecturas de redes número. 11 y 12 fueron las que mostraron menor error de mezclado en la fase de *entrenamiento*, donde ambas clasificaron los lotes de información con un valor inferior al 5 % de error. La diferencia principal entre estas dos, es el tamaño del lote de entrenamiento donde en un caso fue de (1000 x 8) y en el otro de (1500 x 8) respectivamente.

En la etapa de *simulación*, las redes clasificaron la información con un porcentaje de error de mezclado inferior al 4 % y 3 % respectivamente para las sub matrices de mayor tamaño, las cuales son comparables en dimensión a las matrices de entrenamiento. En ambos casos estos valores fueron inferiores para las simulaciones con las sub matrices de menor tamaño. Este comportamiento es posible atribuirlo a que las

sub matrices de reducidas dimensiones representan un espacio muestral más pequeño y con menor variedad de casos posibles, siendo más difícil que existan dos o más vectores de información tan similares que den como resultado la activación de la misma neurona mientras que en los lotes de mayor tamaño esto podría ser más probable.

El análisis visual de los mapas topológicos resultantes para las simulaciones considerando todas las sub matrices mostró que ambas arquitecturas separaron la información en cinco zonas de clasificación, cada una los casos (N-CM-BA-EG) y algo más confusamente el caso CE. Se debe destacar que la arquitectura 12 presentó una menor cantidad de zonas de confusión de datos (así como un menor % de error de mezclado), quedando las regiones mejor delimitadas. Esto resalta la importancia de realizar un proceso de entrenamiento con una importante cantidad de datos que sean diversos y representativos del fenómeno a estudiar. A pesar del costo en tiempo y recursos del proceso de entrenamiento con matrices de grandes dimensiones, en general, será preferible entrenar con grandes lotes de datos cuando se posible, haciendo que la red aprenda la mayor variedad de situaciones.

Se observó que al eliminar el parámetro FA en el proceso de entrenamiento la red no solo finalizó la clasificación con un mayor porcentaje de error sino que convergió más lentamente hacia el resultado. Esto indica que la información que aporta la FA es relevante a la hora de diferenciar los casos de desgaste, ya que ayuda a la red a precisar más rápidamente la información, eventualmente acortando el período de épocas de entrenamiento.

Adicionalmente varios factores hacen que este método de análisis mediante RN y en particular el tipo SOM, sea ventajoso para su futura implementación en ambientes industriales para monitoreo en línea:

- I. Se pueden clasificar procesos que tengan comportamientos no lineales.
- II. La información aparece de manera fácilmente representable en un mapa 2D donde se puede delimitar diferentes zonas de pertenencia en el cual la información va ingresando y clasificándose en el momento.
- III. Esta información puede ser fácilmente interpretada por personal no especializado ya que solamente se debe observar en que región de pertenencia queda posicionada la información.
- IV. El resultado observado en las sub matrices de menor tamaño (250/500 x 8) indican que con adquisiciones cortas de entre 5 a 10 segundos de un proceso de mecanizado como el taladrado, se colecta una cantidad de datos suficientes para que puedan ser clasificados y notar una evolución entre un estado y otro de la condición de la herramienta. Esto implica que idealmente se podría generar un sistema compuesto por adquisición y digitalización en línea de datos EA y parámetros adicionales/ simulación por RN/ interfaz gráfica con el operador de máquina que sea de relativo bajo costo para ser implementado en el control de herramientas de diferentes procesos durante el mecanizado.

BIBLIOGRAFIA

1. H. Appold, K. Feiler, A. Reinhard, P. Schmidt. "Tecnología de los metales" Verlag Handwerk und Technik-traducción Editorial Reverté (1985).
2. C. J. Oxford, Jr., Rochester, Mich. "On The Drilling of Metals, 1 Basic Mechanics of the Process". Transaction of the ASME, 77, 103-144 (1955).
3. T. Childs, K. Maekawa, T. Obikawa, Y Yamane. "Metal Machining – Theory and applications". Arnold (2000).
4. H. Enahoro, M. Welsh. "The relevance of the mechanics of metal cutting to machinability". Proceeding of Machinability, Iron and Steel Institute, 19-24 (1965).
5. M.E. Merchant, "Mechanics of the cutting process", J. Appl Phys, 16, 267-318 (1945).
6. E. J. Armarego, R. H. Brown. "The machining of metals". Prentice Hall (1969).
7. ASM Handbook. "Fatigue and Fracture" Volume 19. ASM International (1996).
8. ASM Handbook. "Machining" Volume 16, ASM International (1996).
9. M. Merchant, "Mechanics of the cutting process", J. Appl. Phys., Vol. 16, 267-318 (1945).
10. V. Piispanen, "Theory of formation of metal chips", Journal of Applied Mechanics, Vol. 19, 876-881 (1948).
11. P. Bridgman "Flow phenomena in heavily stressed metals", J. of Appl. Phys., Vol. 8, 329 (1937).
12. P. Bridgman "On torsion combined with compression", J. of Appl. Phys., Vol. 14, 273 (1943).
13. P. Oxley "mechanics of metal cutting", Int. J. Mach. Tool Des. Res., Vol. 1, 89-97, Pergamon Press (1961).
14. M. Shaw, "The size effect in metal cutting", Sadhana Vol. 28, Part 5, 875-896 (2003).
15. M. Shaw, "A quantized theory of strain hardening as applied to the cutting of metals" J. of Appl. Phys., Vol. 21, 599-606 (1950).
16. Kobayashi and E. Thomsen, "Some observation of the shearing process in metal cutting", Trans. Amer. Soc. Mech. Series B, J. of Eng. for Ind., Vol. 81, 251 (1959).
17. M. Shaw and I. Finnie, "The shear stress in metal cutting", Trans. Amer. Soc. Mech. Engrs, Vol. 77, 115 (1955).
18. A. Cottrell "Conference on the properties of materials at high rates of strain", London: Inst. Mech. Engrs., (1957).
19. T. Sata, "Flow stresses in metal cutting", Sci. Pap. Inst. Phys. Chem. Res. Tokyo, Vol. 53, 188 (1957)
20. J. Zupan, J. Gasteiger. "Neural Networks for Chemists" Angew. Chem. Int. Engl. (1993)
21. H Demuth, M. Beale "Neural Network Toolbox ", The Math Works, Inc. (2002).
22. B. Sick. "On line and indirect tool wear monitoring in turning with artificial neural networks: A review of more than a decade of research", Mechanical Systems and Signal processing (2002) 16(4), p. 487-546.
23. Lin S. and C. Ting, "Drill wear monitoring using neural networks", Int. J. Mach. Tools Manufact., Vol. 36 (1996), 465-475.
24. D.E. Dimla Sr., P.M. Lister, "On –Line metal cutting tool condition monitoring. II: Tool-State classification using multi-layer perceptron neural networks. International Journal of Machine and Manufacture, 40, 769-781(2000).
25. E. Dimla Sr., "Application of perceptron neural networks to tool-state classification in metal-cutting operation", Engineering Applications of Artificial Intelligence, 12, 471-477 (1999).
26. E. Dimla Jr, P Lister, N. Leighton, "Automatic tool state identification in metal turning operation using MLP neural networks and multivariate process parameters", Int. J. Mach. Tools Manufact., 38, No.4, 343-352 (1998).
27. G. Barrera, G. Carreón, A. Ruiz, "control de calidad de piezas cerámicas por medio de análisis de vibraciones y redes neuronales artificiales". Computacion y sistemas, Vol. 8, Num. 3, 187-195 (2005).

28. Yen, Lu, Chen. "Applying the Self-Organization feature map algorithm to AE- based tool wear monitoring in micro-cutting. *Mechanical systems and signal processing*, 34, 353-366 (2013).
29. T. Kohonen."Self –Organizing Maps". Third Edition, Springer (2001).
30. E. Ramasso, V. Placet, R. Gouriveau, L. Boubakar, N. Zerhouni. "Health assessment of composite structures in unconstrained environments using partially supervised pattern recognition tools". Annual conference of the prognostics and health management society (2012).
31. M. Balazinski, E. Czogala, K. Jemialniak, J. Leski. "Tool condition monitoring using artificial intelligence methods". *Engineering applications of artificial Intelligence* 15, 73-80 (2002).
32. N. Godin, S. Huguet, R. Gaertner. "Integration of the Kohonen's self-organising map and k-means algorithm for the segmentation of the AE data collected during". *NDT&E International* 38, 299–309 (2005).
33. Grabec, "Relation between development of defects in materials and acoustic", *Ultrasonics*, p. 9-12, (1980).
34. A. Pollock, "Acoustic Emission Amplitudes", *Non-destructive Testing*, 6, 264-269, (1973).
35. A. Pollock, "Acoustic emission Inspection", PAC 1-14 "Acoustic emission Inspection", PAC Internal Report, TR 103-96-12/89, 29-40 (2003).
36. D. Eshelby, "The interaction of kinks and elastic waves", *Proc. R. Soc. A* 266, 222-246 (1962). C. Scruby, H Wadley, J. Sinclair, "The origin of acoustic emission during deformation of aluminium and aluminium-magnesium alloy", *Philos. Mag. A*, 44, 249-274 (1981).
37. R. K. Miller, E. K. Hill, P. O. Moore. *Nondestructive Testing Handbook*. "Acoustic emission testing" Volume 6 (2005).
38. I. Grabec, P Leskovar, "Acoustic emission of a cutting process", *Ultrasonics* (1977).
39. C. Jiaa and D.Dornfeld, "Experimental studies of sliding friction and wear via acoustic emission signal analysis", *Wear*, 139, 403-424 (1990).
40. V. Baranov, E. Kudryavtsev, G. Sarychev, V. Schavelin, "Acoustic emission in friction", *Tribology and interface engineering series*, No. 53, B.J. Briscoe (2007).
41. T. Philippidis, V. Nikolaidis, A. Anastassopoulos."Damage characterization of carbón/carbón laminates using neural network techniques on AE Signals". *NDT&E International*, Vol. 31, No5, 329-340 (1998).
42. IRAM, "Norma IRAM-Mercosur NM 302 – Terminología de la Emisión Acústica", IRAM (2005).
43. ASTM E 1316-97 b, *Book of Standards*, "Standard Terminology for Nondestructive Testing", ASTM International, W. Conshohocken, PA, USA (1997b).
44. ASTM E 1106 - 86, *Book of Standards*, "Standard Method for primary calibration of acoustic emission sensors", ASTM International, W. Conshohocken, PA, USA (1997a).
45. C.U. Grosse, M. Ohtsu. "Acoustic emission testing" Springer – Verlag Berlin Heidelberg. (2008).
46. M.P Gómez. "Fundamentos de EA" (2012).
47. D. Dornfeld and E. Kannatey Asibu, "Acoustic emission during orthogonal metal cutting", *Int. J. Mech. Sci.*, Vol. 22, 285-296 (1980).
48. E. Kannatey-Asibu, Jr., D. Dornfeld, "Quantitative relationships from orthogonal metal cutting" *Transactions of the ASME*, Vol. 103 (1981).
49. D. Saini, Y Park, "A quantitative model of acoustic emission in orthogonal cutting operations", *Journal of materials processing technology*, Vol. 58, 343-350 (1996).
50. K. Jemielniak, O. Otman, "Tool failure detection based on analysis of acoustic emission signals" *Journal of Materials Processing Technology*. Vol. 76, (1998), 192-197.
51. J. Roget, P Souquet, N. Gsib. "Application of acoustic emission to the automatic monitoring of tool condition during machining", *The American Society for Nondestructive Testing, Materials evaluation*, Vol. 46 (1987).
52. C. E. Everson, S H. Cheraghi. "The application of acoustic emission for precision drilling process monitoring". *Int. J. Mach. Tools Manufact.*, Vol. 39 (1999), 371-387.
53. M.P. Gómez. "Estudio de la señales de EA generadas en el proceso de corte de metales. Aplicaciones a procesos de taladrado." Tesis de Doctorado, UNSAM 2011.

54. M.P. Gómez, A.M. Hey, C.E. D'Attelis and J.E. Ruzzante, "Assessment of cutting tool condition by acoustic emission", *Procedia Materials Science*, *Procedia Materials Science*, Vol. 1 (2012), 321–328.
55. S. R. Ravishankar, C. R. L. Murthy, "Characteristics of AE signals obtained during drilling composite laminates". *NDT&E International*. Vol 33, (2000), 341-348.
56. G. Byrne, D. Dornfeld, I. Inasaki, G. Kettler, W. Koenig and R. Teti, "Tool Condition Monitoring (TCM). The Status of Research and Industrial Application" *Annals of CIRP*, Vol. 44.
57. G. O'Donnell, P. Young, "Towards the improvement of tool condition monitoring systems in the manufacturing environment". *Journal of Materials Processing Technology*. Vol. 119 133-139 (2001),.
58. B. Mascaro, V. Gibiat, M. Bernadou, Y. Esquerre, "Acoustic Emission of the drilling of Carbon/Epoxy Composites" *Forum Acusticum* (2005).
59. H Kikuchi, K. Matsumura, T. Fujiwara, K. Ara, Y. Kamada, S. Kobayashi "Magnetoacoustic Emission Characteristics on Cold Rolled Low Carbon Steel", *Journal of Physics, Conference Series* 266 (2011).
60. Leszek Piotrowski, Boleslaw Augustyniak, Marek Chmielewski, Evangelos V. Hristoforou, and Konstantinos Kosmas, "Evaluation of Barkhausen Noise and Magnetoacoustic Emission Signals Properties for Plastically Deformed Armco Iron", *IEEE Transactions on Magnetics*, Vol. 46, Nro. 2 (2010).

Futuras líneas de Investigación propuestas:

En base a los resultados obtenidos durante el desarrollo del presente trabajo surgen algunas líneas posibles de investigación para ampliar el campo del conocimiento sobre esta temática:

- Ampliación de los casos de estudio variando los parámetros de mecanizados como la velocidad de giro de la broca y por lo tanto el avance.
- Análisis de patrones de brocas con diferentes tipos de recubrimiento y de diferentes materiales.
- Realizar procesos de entrenamiento mucho más extensos (con más cantidad y variedad de datos) de manera de tener mapas con mayor potencia de clasificación.
- Adicionar como variable de análisis la medición de temperatura sobre la herramienta de corte asociada a los parámetros anteriormente estudiados.
- Experimentar este mismo tipo de estudio sobre un centro de mecanizado de alta potencia.

Apéndice A1

Método Hsu Nielsen

Este es un método normalizado mediante el cual se puede comprobar el funcionamiento del equipo de EA. Dicho método consiste en simular una fuente de EA mediante la rotura de una mina de lápiz de características determinadas. Esta rotura produce una onda de tipo explosión con patrones muy bien definidos que pueden ser repetidos al realizar nuevamente el procedimiento. El método brinda entonces la posibilidad de controlar el estado de cada canal del equipo (sensor, acoplamiento, preamplificadores, cables de conexión) a partir de la recepción de la señal de prueba.

El procedimiento se realiza quebrando una mina de lápiz de calidad 2H y 0.5 mm de diámetro (alternativamente 0.3mm) apoyándola sobre la superficie de la pieza en un ángulo de 30 grados. Esta debe sobresalir una longitud de 3mm por sobre el extremo del lápiz. En la Fig. A1. a se puede apreciar un detalle para llevar a cabo el método, y en la Fig. 1. b se observa la implementación de un anillo guía que ayuda a posicionar el lápiz en el ángulo correcto de apoyo.






Fig. A1.1 a. Características del método Hsu Nielsen. **b.** Detalle anillo guía para correcto posicionado del ángulo de rotura.


Apéndice A2

Planos constructivos y despiece de dispositivo de medición de FA.




BASE INFERIOR CON ENCASTRE PARA CELDA DE CARGA.







CORTE A-A CUERPO DE CILINDRO.




TAPA FLOTANTE SUPERIOR



Apéndice A3

Gráficos de FA respecto del Tiempo de ensayo para todas las condiciones de broca ensayadas.





Apéndice A4







Detalle de cantidad de datos pertenecientes al periodo de taladrado con AG y clasificados por condición de broca mediante el parámetro FA

ENSAYO	Empieza señal	Termina Señal	Nro de puntos	Total por tipo de broca
Nueva 1	395	1378	983	3.753 Hits
Nueva 2	280	1183	903	
Nueva 3	360	1270	910	
Nueva 4	259	1216	957	
Crat. Mecanico 1	309	1297	988	6.719 Hits
Crat. Mecanico 2	274	1255	981	
Crat. Mecanico 3	32	884	852	
Crat. Mecanico 4	290	1300	1010	
Crat. Mecanico 5	532	1468	936	
Crat. Mecanico 6	271	1244	973	
Crat. Mecanico 7	323	1302	979	
Crat. Electro Erosion 1	240	1197	957	6.495 Hits
Crat. Electro Erosion 2	352	1295	943	
Crat. Electro Erosion 3	330	1208	878	
Crat. Electro Erosion 4	356	1260	904	
Crat. Electro Erosion 5	368	1218	850	
Crat. Electro Erosion 6	330	1375	1045	
Crat. Electro Erosion 7	310	1228	918	
Broca Achaflanada 1	251	1194	943	2.985 Hits
Broca Achaflanada 2	280	1278	998	
Broca Achaflanada 3	315	1359	1044	
Esquina Gastada 1	357	1281	924	4.556 Hits
Esquina Gastada 2	406	1402	996	
Esquina Gastada 3	399	1310	911	
Esquina Gastada 4	387	1273	886	
Esquina Gastada 5	326	1165	839	
TOTAL				24.508







Apéndice A5

Gráficos de distribución y comportamiento normal de los parámetros medidos para todas las condiciones de broca







BROCA NUEVA









BROCA NUEVA









BROCA CON CRÁTER ELECTRO EROSIÓN









BROCA CON CRÁTER ELECTRO EROSIÓN









BROCA CON CRÁTER MECÁNICO









BROCA CON CRÁTER MECÁNICO









BROCA CON FILO ACHAFLANADO









BROCA CON FILO ACHAFLANADO



BROCA CON ESQUINA GASTADA



BROCA CON ESQUINA GASTADA



Apéndice A6


Matrices de correlación lineal para las cinco condiciones de broca y respecto a todos los parámetros de EA y FA medidos.



NUEVA [N] nro1	FUERZA	AMP	ABSOL-FRQ	RMS	ABS-ENERGY	PM
FUERZA	1.0000					
AMP	-0.1255	1.0000				
ABSOL-FRQ	0.2629	0.1555	1.0000			
RMS	-0.0977	0.5358	0.1104	1.0000		
ABS-ENERGY	-0.0587	0.5148	0.0387	0.4242	1.0000	
PM	-0.0344	0.7748	0.2499	0.6007	0.6629	1.0000
CRAT. MECANICO [CM] nro 3	FUERZA	AMP	ABSOL-FRQ	RMS	ABS-ENERGY	PM
FUERZA	1.0000					
AMP	0.1070	1.0000				
ABSOL-FRQ	-0.3241	0.1740	1.0000			
RMS	-0.1182	0.2607	0.1547	1.0000		
ABS-ENERGY	0.0927	0.6939	0.1507	0.3509	1.0000	
PM	-0.0380	0.7404	0.3817	0.3577	0.8583	1.0000
CRAT. E. EROSION [CE] nro 5	FUERZA	AMP	ABSOL-FRQ	RMS	ABS-ENERGY	PM
FUERZA	1.0000					
AMP	0.0989	1.0000				
ABSOL-FRQ	-0.0159	0.1003	1.0000			
RMS	0.1947	0.2965	-0.0026	1.0000		
ABS-ENERGY	0.1432	0.6913	0.0109	0.3711	1.0000	
PM	0.1374	0.7778	0.0597	0.4441	0.8955	1.0000



BROCA ACHAFLANADA [BA] nro 7	FUERZA	AMP	ABSOL-FRQ	RMS	ABS-ENERGY	PM
FUERZA	1.0000					
AMP	-0.0748	1.0000				
ABSOL-FRQ	-0.2045	0.1116	1.0000			
RMS	-0.1529	0.3194	-0.0846	1.0000		
ABS-ENERGY	-0.0303	0.6887	0.0266	0.3633	1.0000	
PM	-0.0775	0.7252	-0.0200	0.4047	0.8028	1.0000
ESQUINA GASTADA [EG] nro 9	FUERZA	AMP	ABSOL-FRQ	RMS	ABS-ENERGY	PM
FUERZA	1.0000					
AMP	-0.0660	1.0000				
ABSOL-FRQ	0.1197	-0.0924	1.0000			
RMS	-0.2368	0.4032	-0.2552	1.0000		
ABS-ENERGY	-0.0840	0.7405	-0.1500	0.5499	1.0000	
PM	-0.1438	0.6243	-0.2150	0.7270	0.8146	1.0000


Apéndice A7

Valores medios de los parámetros respecto su desvío estándar para cada condición de ensayo














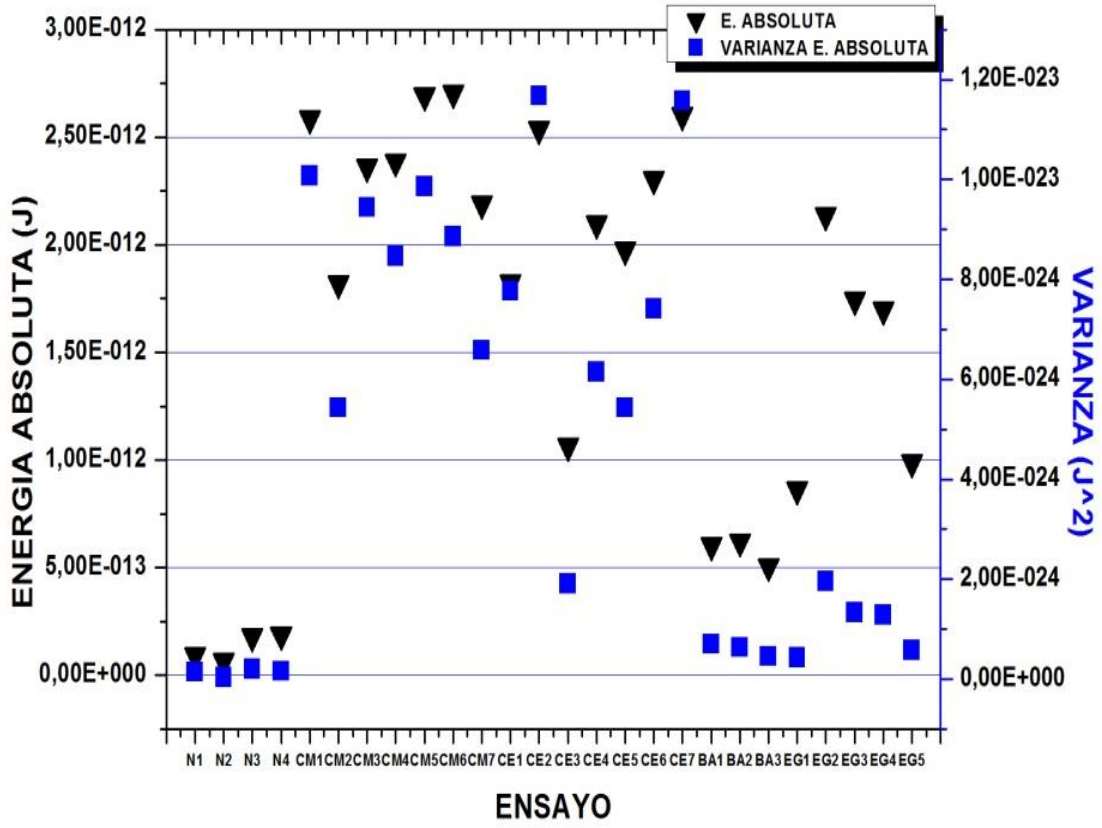
Apéndice A8

Valores medios de los parámetros respecto de sus varianzas para todas las condiciones de ensayo.









Apéndice A9

Detalle de las diferentes arquitecturas y configuraciones de Redes Neuronales probadas.

Variables de la Red Neuronal.-

Tamaño de la Red	Net size		Definido por el usuario
Geometría de la red	Geometry	1	Planar
		2	Toroidal
Función Topológica de corrección de la vecindad	Topological function	1	Triangular
		2	Gausiana
		3	Constante
Vecino más lejano. (tamaño de la vecindad)	Farest neighbour		Definido por el usuario
Tipo de neurona Ganadora	Kind of winner	1	Salida más grande
		2	Salida mas parecida a dato de entrada
Max. Y Min. Corrección de pesos	Max & Min corr. factor		Definido por el usuario
Numero de épocas	Number of epochs		Definido por el usuario
Máximo valor absoluto de los pesos	Max. Abs. Value W		Definido por el usuario
Tamaño del lote de entrenamiento	Tamaño Lote		Definido por el usuario
Actualización de los pesos	TCF	1	Por época
		2	Por vector de entrada
		3	Por vector y época

Arquitectura Nro 1

Norm ratio: 0.021251 ,Consecutive mixing error 7.5

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 1 Topological function : 1

Farest neighbour : 15 Kind of winner : 2

Max & Min corr. factor: 0.90 0.05

Number of epochs : 500 Max. Abs. Value W: 0.0001

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 2

Norm ratio: 0.019332 ,Consecutive mixing error 8.2

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 1 Topological function : 2

Farest neighbour : 15 Kind of winner : 2

Max & Min corr. factor: 0.90 0.10

Number of epochs : 500 Max. Abs. Value W: 0.0001

Tamaño Lote : 1000x8 TCF : 2

Arquitectura Nro 3

Norm ratio: 0.015563 ,Consecutive mixing error 6.9

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 1 Topological function : 2

Farest neighbour : 15 Kind of winner : 2

Max & Min corr. factor: 0.90 0.10

Number of epochs : 500 Max. Abs. Value W: 0.0001

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 4

Norm ratio: 0.020623 ,Consecutive mixing error 6.9

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 1 Topological function : 2

Farest neighbour : 15 Kind of winner : 2

Max & Min corr. factor: 0.90 0.05

Number of epochs : 500 Max. Abs. Value W:
0.001

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 5

Norm ratio: 0.016950 ,Consecutive mixing error 6.4

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 1 Topological function : 2

Farest neighbour : 11 Kind of winner : 2

Max & Min corr. factor: 0.70 0.10

Number of epochs : 500 Max. Abs. Value W:
0.010

Tamaño Lote : 1000x8 TCF : 2

Arquitectura Nro 6

Norm ratio: 0.015787 ,Consecutive mixing error 7.6

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 2 Topological function : 2

Farest neighbour : 11 Kind of winner : 2

Max & Min corr. factor: 0.70 0.10

Number of epochs : 500 Max. Abs. Value W:
0.010

Tamaño Lote : 1000x8 TCF : 2

Arquitectura Nro 7

Norm ratio: 0.016516 ,Consecutive mixing error 7.3

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 1 Topological function : 2

Farest neighbour : 11 Kind of winner : 2

Max & Min corr. factor: 0.70 0.10

Number of epochs : 1000 Max. Abs. Value W: 0.010

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 8

Norm ratio: 0.014725 ,Consecutive mixing error 6.5

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 2 Topological function : 2

Farest neighbour : 11 Kind of winner : 2

Max & Min corr. factor: 0.70 0.10

Number of epochs : 1000 Max. Abs. Value W: 0.010

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 9

Norm ratio: 0.016686 ,Consecutive mixing error 6.0

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 1 Topological function : 2

Farest neighbour : 5 Kind of winner : 2

Max & Min corr. factor: 0.70 0.10

Number of epochs : 500 Max. Abs. Value W: 0.010

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 10

Norm ratio: 0.016362 ,Consecutive mixing error 7.3

Values of net architecture and running parameters

Net size (Rows x Cols): 40 40

Geometry : 2 Topological function : 2

Farest neighbour : 5 Kind of winner : 2

Max & Min corr. factor: 0.50 0.10

Number of epochs : 500 Max. Abs. Value W:
0.010

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 11

Error control

Norm ratio: 0.008386 Consecutive mixing error 2.8

Values of net architecture and running parameters

Net size (Rows x Cols): 50 50

Geometry : 1 Topological function : 2

Farest neighbour : 17 Kind of winner : 2

Max & Min corr. factor: 0.90 0.10

Number of epochs : 500 Max. Abs. Value W:
0.0001

Tamaño Lote : 1000x8 TCF : 3

Arquitectura Nro 12

Norm ratio: 0.017016 Consecutive mixing error 0.5

Values of net architecture and running parameters

Net size (Rows x Cols): 50 50

Geometry : 1 Topological function : 2

Farest neighbour : 17 Kind of winner : 2

Max & Min corr. factor: 0.60 0.10

Number of epochs : 500 Max. Abs. Value W:
0.0001

Tamaño Lote : 1500x8 TCF : 3