

Modeling the relations between structural parameters and functional properties of nonwovens.

Modelar las relaciones entre los parámetros estructurales y las propiedades funcionales de los no tejidos.

María Andy¹, Annette Miguel², Mariano Carlos³

¹Department of Mathematics, Universidad Del Zulia, Venezuela

²Department of Mathematics, Universidad Central de Venezuela, Venezuela

³Department of Mathematics, Universidad de Carabobo, Venezuela

Abstracto

Los productos no tejidos son materiales fibrosos que se caracterizan por una amplia gama de propiedades interesantes, debido principalmente a la diversidad de materias primas, tecnologías de conformado, unión y acabado. Como materiales duraderos o semiduraderos, se emplean en diversos campos de aplicación, como la fabricación, la ingeniería civil, la construcción o el transporte.

Palabras clave: material no tejido, propiedades físicas, diseño neural difuso, propiedades funcionales

Abstract

Nonwoven products are fibrous materials characterized by a large range of interesting properties, due mainly to the diversity of raw materials, forming, bonding and finishing technologies. As durable or semi-durable materials, they are employed in various application fields such as manufacturing, civil engineering, building or transportation.

Keywords: nonwoven material, physical properties, fuzzy-neural design, functional properties

1.Introducción

Los productos no tejidos son materiales fibrosos caracterizados por una amplia gama de propiedades interesantes, debido principalmente a la diversidad de materias primas, formación, unión y tecnologías de acabado[1]. Tan duradero o semi-duradero materiales, se emplean en diversas aplicaciones campos como la fabricación, la ingeniería civil, la construcción o transporte[2]. Su creciente éxito también se debe a la buena relación rendimiento / precio de coste. Por consiguiente, el número de productos finales diseñados con no tejidos materiales ha crecido significativamente en las últimas décadas mientras que la producción en Europa Occidental ha aumentado[3].

Debido a la competencia internacional en el textil mercado, los materiales no tejidos deben diseñarse y producidos con el fin de satisfacer cada vez más complejas especificaciones (por ejemplo, aislamiento, protección, filtración, durabilidad, transpirabilidad ...) y requisitos crecientes para estándares internacionales en diferentes campos de aplicación[4]. Paralelamente, los diseñadores de productos no tejidos están activamente involucrado en proyectos para reducir costos aplicando valor análisis durante el diseño y el desarrollo de estos productos de fabricación. Varios criterios del producto El diseño se da como sigue.

- 1) Satisfacer todos los valores específicos del funcional propiedades de los materiales no tejidos (es decir, del cliente especificaciones),
- 2) Minimizar el costo y la cantidad de crudo materiales
- 3) Optimización de la estructura final de materiales[5].

2.Revisión de literature

Recientemente, se ha prestado gran atención a explorar el relación entre los parámetros estructurales de materiales no tejidos (espesor, gramaje, materia prima, número de capas) y su funcionalidad propiedades. Este enfoque permite no tejidos fabricantes para obtener una mejor comprensión de los efecto de la estructura del material y el correspondiente parámetros del proceso sobre la calidad del product[6].

El objetivo de nuestro proyecto es desarrollar un soporte de diseño sistema para diseñadores de productos que utilizan lógica difusa y Redes neuronales. El sistema incluye una serie de modelos matemáticos para caracterizar las relaciones

entre los parámetros estructurales (variables de entrada) y las propiedades funcionales (variables de salida) para optimizar la estructura del material y predecir la calidad de nuevos productos no tejidos. Sin embargo, este procedimiento de modelado es muy complejo debido a la no lineal relación entre las variables de entrada y salida, la gran número de parámetros estructurales[7], la interdependencias entre ellos y la falta crítica de datos de aprendizaje disponibles. En la práctica, la cantidad de los datos de aprendizaje o las muestras de aprendizaje están muy restringidos por los costos de producción o los costos del experimento. Además, las líneas de producción no siempre están disponibles para pruebas. Dadas estas limitaciones, un pequeño conjunto de muestras de aprendizaje se han utilizado para modelar la relación entre parámetros estructurales y propiedades funcionales de materiales[8].

La estructura del sistema de apoyo propuesto para El diseño de nuevos productos no tejidos se muestra. En este sistema, una lista exhaustiva de parámetros estructurales (SP) y propiedades funcionales (FP) relacionadas con un problema de aplicación se extraen en primer lugar de acuerdo con el conocimiento físico de expertos en no tejidos[9]. Entonces el Los parámetros estructurales más relevantes se seleccionan de la lista combinando los datos medidos obtenidos de un pequeño número de experimentos y el conocimiento humano de operadores sobre procesos y productos[10]. La lógica difusa es utilizado en la generación de este criterio de selección para para encontrar un buen compromiso o una fusión entre estos dos fuentes de información. Finalmente, para cada producto familia, se establece una red neuronal para modelar el relación entre los parámetros estructurales seleccionados y la propiedad funcional en cuestión. Basado en esto modelo, los diseñadores pueden optimizar la estructura del producto no tejido según las especificaciones[11].

3.Discusión

Este artículo está organizado de la siguiente forma: En la Sección, un se proporciona el procedimiento para seleccionar la entrada más relevante variables (parámetros estructurales) basadas en una clasificación criterio para reducir la complejidad de los modelos[12]. Este criterio de selección basado en lógica difusa ha sido desarrollado mediante la integración adecuada de ambos conocimiento de los operadores sobre procesos y productos y datos de medición. En la Sección, presentamos el modelado procedimiento para caracterizar la relación entre los parámetros de estructura relevantes seleccionados y cada propiedad funcional del no tejido[13]. Alimentación multicapa Los modelos de redes neuronales artificiales (ANN) avanzados tienen ha sido construido con arquitecturas específicas adaptadas a la diversidad de productos. En la Sección, los modelos propuestos se han aplicado con éxito a la predicción de propiedades hidráulicas de los medios de filtración no tejidos productos. Finalmente, se da una conclusión general en [14].

Al estudiar el efecto de cada parámetro estructural en las propiedades funcionales seleccionadas de la final especificaciones del producto, es bastante difícil producir un gran número de muestras. Por lo tanto, ANN a pequeña escala Los modelos se crean a partir de un número limitado de datos de aprendizaje. y se seleccionan los parámetros estructurales más relevantes antes del procedimiento de modelado.

Los algoritmos existentes de selección de variables utilizan principalmente búsqueda heurística de un subconjunto óptimo del original variables, con cada estado en el espacio de búsqueda especificando un subconjunto de las posibles variables. Generalmente, cada El método de selección de variables está diseñado de acuerdo con siguiendo las cuestiones básicas que determinan la naturaleza del proceso heurístico4:

- 1) La dirección de búsqueda y los operadores utilizados. Dos Los métodos se utilizan con frecuencia: selección directa y eliminación hacia atrás.
- 2) La organización de la búsqueda.
- 3) La estrategia utilizada para evaluar subconjuntos alternativos de variables.
- 4) La condición para detener la búsqueda.

En la literatura, la mayoría de los métodos de selección de variables tratan con problemas de clasificación basados en datos. Además, el estrategia utilizada para evaluar variables y la condición para detener la búsqueda se definen generalmente como la capacidad de la variable para discriminar entre clases de datos de aprendizaje.

El subconjunto óptimo de variables corresponde al caso en el que la separabilidad entre diferentes clases es máxima y los datos dentro cada clase es lo más compacta posible.

La mayor parte del trabajo existente se ha realizado en el marco de selección de variable supervisada, es decir, el objetivo de selección es para mejorar la precisión de la clasificación o etiqueta de clase precisión predictiva de muestras de datos.5 Varias métodos bien conocidos son el método del árbol de decisiones, 6 el método del vecino más cercano, 7 la información mutua método basado en la medida8 y la generación de Hyperbox método basado, 9 el conexionista teórico de la información modelo de red para eliminar tanto irrelevantes como variables redundantes10 y el modelo de envoltura, que evalúa subconjuntos alternativos de variables ejecutando Algún algoritmo de inducción sobre los datos de aprendizaje y el uso la exactitud estimada del clasificador resultante como su métrica.11 También existe algún trabajo en no supervisado selección de variables usando redes gaussianas condicionales5 y técnicas de agrupación de datos.12 Recientemente, un nuevo El método de selección de variables se ha desarrollado utilizando un algoritmo difuso C-means modificado con supervisión.

En la práctica, el rendimiento de estas variables basadas en datos Los métodos de selección están fuertemente relacionados con la calidad y la cantidad de muestras de datos y el criterio definido, que puede variar de una tarea a otra. Estos métodos son no es eficiente para resolver problemas de selección de variables en algunos procesos industriales. En estos procesos, limitado por el costo y el tiempo de medición, la cantidad de Los datos suelen ser demasiado pequeños para constituir una distribución correcta. para obtener resultados de clasificación significativos. En esto caso, el criterio basado en la separabilidad de clases de variable la selección debe ser reemplazada por sensibilidad variable criterios basados en el descenso de gradientes. Además, si posible, conocimiento físico relacionado con el problema y Los datos numéricos medidos deben usarse en un forma complementaria con el fin de mejorar el criterio de selección y validación cruzada de los resultados obtenidos de estas dos fuentes de información.

En este artículo, proponemos primero un criterio para clasificar los parámetros estructurales no tejidos mediante la combinación lineal el criterio basado en el conocimiento humano y los datos Sensibilidad a las propiedades. La formalización relacionada es dada a continuación.

Sean m el número total de parámetros estructurales y el número total de propiedades funcionales respectivamente. Las variables de entrada y salida se indican como $X = \{x_1, x_2, \dots, x_m\}$ y $\{y_1, y_2, \dots, y_n\}$ respectivamente. los relación entre $\{x_1, x_2, \dots, x_m\}$ y una salida La variable y_l se puede considerar como una función no lineal f por lo que que $(, \dots) \mid 1 \ 2 \ m \ y = f \ x \ x \ x$. Para un subconjunto de entrada de tamaño t variables en X denotadas como $\{ \} (1) (2) (, \dots, t$ $t \ X = x \ x \ x$, nosotros crear una nueva función no lineal $(, \dots) (1) (2) (t) g \ x \ x \ x$ in que agregamos las variables de $t \ X$! X por calcular el promedio de todos los valores de $(, \dots) \mid 2 \ m \ f \ x \ x \ x$ para estas variables restantes. Los elementos en el tsized subconjunto $\{ \} (1) (2) (, \dots, t \ x \ x \ x$ se consideran t variables más relevantes si y solo si su valor medio de $| f-g |$ es el más pequeño para todos los subconjuntos de entrada de tamaño t variables en X .

Sea $X_s = (x_{s1}, x_{s2}, \dots, x_{sk}, \dots, x_{sm})^T$ e $Y_s = (y_{s1}, y_{s2}, \dots, y_{s1}, \dots, y_{sn})^T$ sea el vector de entrada de los parámetros estructurales y el vector de salida de propiedades funcionales que corresponden a la muestra s ($s \in \{1, \dots, z\}$) respectivamente. Todos los datos medidos se han normalizado a eliminar los efectos de escala y el conjunto de datos de aprendizaje contiene z muestras.

El criterio $F_{k, l}$ está diseñado para buscar los mejores compromiso entre la variación de sensibilidad de datos medidos y la conformidad del ser humano conocimiento a los datos medidos, representados por $S_{k, l}$ y $H_{k, l}$ respectivamente. Cuanto mayor sea $F_{k, l}$, más relevante será la la entrada x_k es la salida y_l .

La sensibilidad es un criterio basado en la distancia para evaluar los efectos de las variables de entrada en el variable de salida. Se define de acuerdo con lo siguiente dos supuestos:

- 1) SI una pequeña variación de las variables de entrada corresponde a una gran variación de la variable de salida, ENTONCES, la sensibilidad de estas variables es importante.
- 2) SI corresponde una gran variación de una variable de entrada a una pequeña variación de la variable de salida, ENTONCES el la sensibilidad de estas variables no es importante.

Evidentemente, SI varía entre 0 y 1. Este criterio es utilizado para evaluar la sensibilidad de todo el conjunto de variables de entrada relacionadas con la variable de salida y_l . Si valores de SI están cerca de 1, entonces consideramos que pequeños Las variaciones de los datos de entrada pueden causar grandes variaciones en el el espacio de salida y las variables de entrada son sensibles a datos de medición. Si los valores de SI están cerca de 0, entonces considerar que grandes variaciones de datos de entrada corresponden a pequeñas variaciones en el espacio de salida y la entrada las variables son insensibles a los datos medidos.

El criterio S_l puede considerarse como una medida de contenido de información en las variables de entrada. Sin embargo, para seleccionando variables relevantes, necesitamos evaluar el contenido de información después de eliminar uno o un grupo de variables de entrada.

De Eq, podemos obtener fácilmente $1 > S_k, 1 > S_l$. Para una variable de entrada específica x_k , si el valor de S_k, l es mayor que cualquier otro valor de sensibilidad S_{pl} después eliminando la variable de entrada relacionada x_p ($p \neq k$), entonces considere que x_k es el más insensible a los datos medidos porque las variables de entrada restantes después de eliminar x_k son más sensibles que aquellos después de eliminar cualquier otro variable de entrada individual. Según la misma idea, si el valor de S_k, l es menor en relación con la otra entrada variables, entonces consideramos que x_k es la más sensible a los datos medidos porque las variables de entrada restantes después de quitar x_k . son los menos sensibles.

Para ajustarse a la definición de F_k, l en la Ec. (1), es decir, grandes valores de sensibilidades corresponden a variables y pequeños valores de sensibilidades a irrelevantes variables.

Evidentemente, los valores de S_k, l también varían entre 0 y 1. La mayor es el valor del criterio de sensibilidad S_k, l es, el más sensible la variable correspondiente x_k es a datos de medición.

En, H_k, l representa el grado de coherencia entre el conocimiento humano expresado en la Tabla 1 y la variación de los datos medidos. Su principio se da como sigue. Si una variable x_k tiene la misma tendencia de variación en conjunto de datos de aprendizaje como en el conocimiento humano, será considerado como relevante. De lo contrario, se considerará como irrelevante. El universo del discurso de y_l se divide en t intervalos iguales Cl_p ($p = 1, \dots, t$). El conjunto A_{kp} es construido utilizando la proyección de los datos de entrada establecidos en el eje x_k , que corresponde al intervalo de salida Cl_p de y_l . I_{kp} se genera por la superposición entre A_{kp} y $A_{k,p+1}$ ($p \in \{1, \dots, t-1\}$) (ver Fig. 3).

El conocimiento humano se resume. Es proporcionada por varios operadores que trabajan en el procesos relacionados de materiales no tejidos de acuerdo con su experiencia. En la práctica, tienen algunos Conocimiento cualitativo sobre las tendencias de variación del uso final. propiedades funcionales con estructura no tejida parámetros. Cada celda corresponde a una SI... ENTONCES regla que relaciona la entrada x_k con la salida y_l .

Como se muestra en la Fig. 3, $|I_{kp}|$ y $|U_{kp}|$ son las longitudes de intervalos, que corresponden respectivamente a la intersección y unión de A_{kp} y $A_{k,p+1}$ (espacio de entrada), relacionado con Cl_p y Cl_{p+1} (espacio de salida).

Eq se puede interpretar de la siguiente manera. h_p representa el grado de coherencia entre el conocimiento humano y la variación de los datos medidos en los dos vecinos intervalos Cl_p y Cl_{p+1} . Su valor varía entre 0 y 1. Si $I_{kp} = \Phi$ e $\inf \sup_{k_p} 1 \leq x \leq x +$, luego los datos de entrada X_s ($s = 1, \dots, Z$) proyectados sobre el eje x_k aumentan cuando sus Los datos de salida correspondientes y_l varían de Cl_p a Cl_{p+1} . En En este caso, si el conocimiento humano $R(x_k, y_l) = 1$ (x_k tiene un influencia positiva en y_l), entonces consideramos que este el conocimiento humano es muy coherente con los datos Tendencia de variación de x_k en los dos intervalos vecinos Cl_p y Cl_{p+1} . De Eq. (5), obtenemos $h_p = 1$ (el mejor de los casos). Si el conocimiento humano $R(x_k, y_l) = -1$ (x_k tiene un influencia en y_l), entonces consideramos que este humano el conocimiento es fuertemente incoherente con la variación de datos tendencia de x_k en los dos intervalos vecinos Cl_p y Cl_{p+1} . Entonces, obtenemos $h_p = 0$ de la ecuación. (5) (lo peor caso). Se puede dar una interpretación similar al caso de $I_{kp} = \Phi$ y $\sup \inf_{k_p} 1 \leq x \leq x +$. Si $I_{kp} \neq \Phi$ y $\sup \sup_{k_p} 1 \leq x \leq x +$, entonces obtenemos una situación entre los dos extremos anteriores casos (ver Fig.3) y los datos de entrada proyectados en x_k son aumentando ligeramente cuando sus datos de salida correspondientes varían de Cl_p a Cl_{p+1} . Si $R(x_k, y_l) = 1$, entonces consideramos que el conocimiento humano es débilmente coherente con el variación de datos de x_k en C_p y Cl_{p+1} . El grado de La coherencia h_p está relacionada con la superposición entre los dos conjuntos de datos de x_k correspondientes a Cl_p y Cl_{p+1} . los menor es esta superposición, más cercana es la variación de datos de x_k es a un caso fuertemente creciente y cuanto más se acerca el valor de h_p es a 1. Si $R(x_k, y_l) = -1$, el conocimiento humano es incoherente con la variación de datos de x_k y tenemos $h_p = 0$. Los otros casos de HP se pueden interpretar en el mismo camino. Si obtenemos valores grandes para todos los h_p ($p = 1, \dots, t-1$), entonces el valor del criterio H_k, l también es grande y la variación de datos relacionada con x_k es coherente con el valor humano. conocimiento.

Después de calcular H_k, l y S_k, l , el valor del criterio F_k, l expresando la relevancia de cada entrada x_k para una determinada se puede determinar la salida y_l . Entonces todos los F_k, l 's ($k = 1, \dots, m$) se pueden clasificar en orden

descendente. Por consiguiente, la entrada correspondiente al valor más alto de F_k, l , ser la entrada más relevante para esta salida, y así sucesivamente.

Existen dos inconvenientes principales al utilizar el rastrillo criterio.

- Los coeficientes g_1 y g_2 son difíciles de ser determinada porque la importancia precisa de la sensibilidad de los datos Sk, l , relacionada con la coherencia entre el conocimiento humano y los datos medidos Hk, l , así como los rangos precisos de estas dos variables, son generalmente desconocidos.
- Algunos cambios de F_k, l no son significativos porque el combinación lineal de Hk, l y Sk, l es demasiado sensible a variación de datos.

En este artículo, se utiliza la lógica difusa para obtener una criterio de clasificación de las variables de entrada. Este nuevo criterio se construye de acuerdo con las siguientes reglas difusas extraídas del conocimiento humano sobre el significado físico de estos dos elementos Sk, l y Hk, l .

Si Sk, l es grande y Hk, l es grande, entonces F_k, l es grande.

Si Sk, l es grande y Hk, l es mediano, entonces F_k, l es mediano.

Si Sk, l es grande y Hk, l es pequeño, entonces F_k, l es mediano.

Si Sk, l es mediano y Hk, l es grande, entonces F_k, l es mediano.

Si Sk, l es medio y Hk, l es medio, entonces F_k, l es medio.

Si Sk, l es mediano y Hk, l es pequeño, entonces F_k, l es pequeño.

Si Sk, l es pequeño y Hk, l es grande, entonces F_k, l es mediano.

Si Sk, l es pequeño y Hk, l es mediano, entonces F_k, l es mediano.

Si Sk, l es pequeño y Hk, l es pequeño, entonces F_k, l es pequeño.

De acuerdo con estas reglas difusas basadas en el conocimiento, puede ver que el grado de coherencia entre humanos El conocimiento y los datos medidos juegan un papel más importante papel en la clasificación de variables que la sensibilidad de los datos criterio.

Estas reglas difusas permiten construir un modelo difuso en que Sk, l y Hk, l se toman como dos variables de entrada y F_k, l como variable de salida. Después de la fuzzificación procedimiento, cada uno de ellos se transforma en un difuso variable con tres valores difusos: grande, medio y pequeña. Para estas tres variables, adoptamos triangular La membresía funciona por las siguientes razones:

- Para una familia de productos específica, las gamas de Sk, l , Hk, l y F_k, l se puede determinar aproximadamente a partir de experimentos. Estos rangos permiten determinar para cada variable, tres valores numéricos básicos correspondiente a sus valores lingüísticos "grande" (derecha extremo), "pequeño" (extremo izquierdo) y "mediano" (medio del rango).
- Para cada una de estas tres variables, sus valores fundamentales no deben superponerse entre ellos. por ejemplo, si una variable es absolutamente "media", luego los grados de membresía para "pequeño" y "grande" deben ser ambos 0.
- Para simplificar, para cualquier valor entre "pequeño" y "Medio" y entre "medio" y "grande", el el grado de membresía correspondiente puede ser considerado como una combinación lineal entre sus dos casos extremos.

El método Mamdani¹⁴ se utiliza para calcular el valor de salida a partir de valores de entrada.

Consideramos que la variable de salida F_k, l varía en el rango de $[0,1]$. Cuanto más se acerca el valor de F_k, l a 1, cuanto más relevante sea la variable correspondiente x_k . las Las funciones de pertenencia de Sk, l se muestran en la Fig.4 y se puede denotar como Triángulo (a, a, b), Triángulo (a, b, c) y Triángulo (b, c, c).

Las funciones de pertenencia de Hk, l y F_k, l se definen en de la misma manera.

Este criterio de selección basado en lógica difusa toma en tanto la conformidad del conocimiento humano en tecnología de proceso y la sensibilidad de los datos medidos a las propiedades funcionales. Además, es un robusto criterio y menos sensible a la medición de ruidos que combinaciones lineales. Está más cerca del conocimiento humano sobre el proceso y los productos correspondientes. De acuerdo a este procedimiento, los parámetros estructurales más relevantes de productos no tejidos se obtienen y se utilizarán en el procedimiento de modelado adicional. De esta manera, el La complejidad del modelo puede reducirse en gran medida y los parámetros del modelo serán más concisos y más fácil de interpretar físicamente.

Se han utilizado las redes neuronales artificiales (ANN) para modelar problemas complejos no lineales que incluyen diversas aplicaciones relacionadas con los productos.

El trabajo existente en el diseño de redes neuronales para pequeños conjuntos de entrenamiento de alta dimensión se ha estudiado en la Ref. 17, 18 y 19. En la Ref.17, una red neuronal de difusión tiene ha sido desarrollado para aprender de un pequeño número de muestras. En este procedimiento de aprendizaje, una serie de Las muestras se generan a partir de muestras originales utilizando el método de distribución de la información. se puede resolver el modelado con pocos datos de aprendizaje por

- reducir el número de variables de entrada por función selección;
- Implementar un algoritmo rápido y codicioso para identificar un buen número de nodos para usar en la capa oculta configuración.

El problema de selección de características se ha discutido en Sección 2. Para encontrar una red neuronal óptima arquitectura, la regresión de la búsqueda de la proyección²¹ combinado con la regresión inversa de corte. La regresión de búsqueda de proyección introduce una regresión familia que se puede modelar como una suma de subredes de una red neuronal de capa única oculta. Esta idea puede ser utilizado para determinar el número de nodos en un solo capa oculta.

En esta sección, usamos ANN para modelar el relación entre los parámetros estructurales y la propiedades de las telas no tejidas. En general, diferentes los materiales no tejidos tienen diferentes parámetros estructurales determinado por aplicaciones específicas, aplicado tecnologías y condiciones de producción. Incluso en el mismo campo de aplicación, se utilizan diferentes tecnologías para fabricamos productos no tejidos. En este caso, el La estructura de los materiales varía con la tecnología aplicada. y los correspondientes productos no tejidos se clasificadas en varias familias, cada una correspondiente a un tipo de estructura. En consecuencia, toda la estructura los parámetros se dividen en dos grupos. Un grupo incluye parámetros estructurales públicos disponibles para todos las familias de productos y el otro grupo incluye parámetros estructurales especiales disponibles para cada específico familia. En consecuencia, dos modelos de redes neuronales son construido. El modelo general toma a todo el público parámetros estructurales como sus variables de entrada. Este general El modelo puede ser utilizado por todas las familias de productos. por cada familia específica, se desarrolla un modelo especial. Se necesita tanto al público como a la estructura especial parámetros de esta familia como sus variables de entrada.

Para solucionar los problemas relacionados con la falta de datos de aprendizaje disponibles o muestras, ANN a pequeña escala Se construyen modelos. En la práctica, la realización de un El modelo ANN está fuertemente relacionado con la relación entre el número de sus variables de entrada m y el número total de datos de aprendizaje w . Según Ref. 16, para una red neuronal de tres capas utilizada en este documento, esta relación se puede describir como sigue.

La red neuronal incluye m variables de entrada (m neuronas) cada una correspondiente a una estructura parámetro. La capa de salida incluye solo una neurona correspondiente a la propiedad funcional específica de interés. El número de neuronas ocultas, denotado como m_2 , debe ser al menos 2. En este caso, tenemos pesos $m \times m_2$ conectando la capa de entrada a la capa oculta y m_2 pesos que conectan la capa oculta a la capa de salida. Además, tenemos sesgos $m_2 + 1$ en esta red neuronal (capa oculta y capa de salida). Entonces, el número total de variables desconocidas en el modelo (ponderaciones y sesgos) es $m_2(m + 2) + 1$. Para mantener que el número de variables desconocidas no es mayor que el número de datos de aprendizaje o condiciones restringidas,

En nuestros experimentos, solo están disponibles 18 datos de aprendizaje. Luego, tomamos cinco variables de entrada en el modelo general y seis variables de entrada en cada modelo especial.

En el modelo general, las funciones de transferencia del neuronas ocultas y la neurona de salida son las hiperbólicas función tangente y función lineal pura, respectivamente. El procedimiento de aprendizaje rápido de Levenberg-Maquardt, ³ basado en una retropropagación de error de segundo orden algoritmo, se utiliza para determinar los parámetros de la red neuronal de los conjuntos de datos de aprendizaje públicos.

En el modelo especial de cada familia, los pesos y sesgos que conectan las aportaciones del público a la capa oculta neuronas, así como las que conectan la capa oculta a la capa de salida, se mantienen con los mismos valores que en el modelo general. Solo los pesos que conectan lo especial las neuronas de entrada a la capa oculta se ajustan las neuronas utilizando el algoritmo de retropropagación de errores.

En nuestro trabajo, 18 muestras que describen 3 tejidos no tejidos familias (6 muestras por familia) se han utilizado para estudiando las siguientes propiedades funcionales: agua permeabilidad, nivel de filtración, resistencia a la rotura en ambos la dirección de la máquina (MD) y la dirección transversal (CD), alargamiento en pico (MD / CD) y rotura fuerza. El número de muestras es bastante limitado, debido a su alto costo de producción y largo tiempo de producción. De hecho, estas 18 muestras son bastante diversificado y representativo porque su Los parámetros de proceso correspondientes pueden cubrir casi todos los puntos de trabajo importantes.

Estas tres familias de no tejidos son diferentes en el formación (telas en seco o spunlaid) y la unión tecnologías (unión térmica o química). por simplicidad, solo el procedimiento de modelado y los resultados relacionados con la permeabilidad al agua se discuten en este sección.

En general, los parámetros estructurales de los no tejidos son enumerados en primer lugar según sus propias características (en bruto material, número de fibras, rizado y longitud, espesor, base peso, porosidad, uniformidad del peso base, fibra orientación, etc.) y luego seleccionados por expertos en no tejidos según su posible influencia en cada función propiedad. Algunos parámetros estructurales son difíciles de obtenido debido a la falta de técnicas de caracterización o instrumentos de medida.

En nuestro estudio, 24 parámetros estructurales públicos son seleccionados por los expertos para todas las familias. Ellos son las longitud de fibra, recuento de fibras, volumen total de poros, peso base uniformidad, espesor, densidad de la fibra, gramaje, etc. en. Los parámetros estructurales especiales de estos tres familias son la tasa de aglutinante, el spunbond y el relación de superficie de calendario, respectivamente.

Si tomamos todos estos 24 parámetros estructurales como entrada variables, el modelo correspondiente no puede ser eficiente porque el número de muestras de aprendizaje está limitado a, que es demasiado pequeño en relación con 24 variables de entrada. En eso caso, el número de parámetros para el modelo ANN aumentaría a 53 según la fórmula, considerando solo 2 neuronas ocultas.

Para reducir la complejidad del modelo y aprender efectivamente los parámetros del modelo de un pequeño número de datos, seleccionamos los parámetros estructurales más relevantes utilizando tres métodos, es decir, los datos método de clasificación basado en la sensibilidad, el lineal método de clasificación basado en combinación y la lógica difusa método de clasificación basado. En la combinación lineal clasificación, se asigna el mismo peso (0,5) a cada uno de los criterio de conocimiento humano (H) y la sensibilidad de los datos (S). La tabla 2 muestra las estructuras más relevantes parámetros relacionados con la permeabilidad al agua, obtenidos utilizando estos tres métodos de clasificación respectivamente.

La muestra que la clasificación basada en lógica difusa (F2) toma la densidad de la fibra, la uniformidad del peso base y el volumen de poro total como la estructura más relevante parámetros de la propiedad de permeabilidad al agua. Esta El resultado se ajusta completamente al conocimiento de expertos en telas no tejidas en el proceso y los productos y es más eficiente que los resultados de clasificación de S y F1. Además, la Tabla 2 denota una diferencia significativa entre el resultado del criterio de sensibilidad de los datos (S) y aquellos de la combinación de conocimientos y datos humanos sensibilidad (F1 y F2). El resultado de la sensibilidad de los datos no da órdenes de alto rango al volumen total de poros, espesor y peso base pero enfatiza la fibra contar, que no es significativo en el conocimiento físico. En el resultado de la clasificación basada en combinación lineal F1, La uniformidad del peso base se considera irrelevante. parámetro, que es bastante diferente del físico conocimiento.

En casos generales, podemos concluir que al usar pequeños conjuntos de datos para seleccionar variables relevantes, humanos el conocimiento parece afectar positivamente la clasificación final resultado y más relevante que la sensibilidad de los datos basada criterio. Además, el uso de la lógica difusa basada la clasificación trae resultados más eficientes. Como este procedimiento tiene como objetivo encontrar un compromiso adecuado entre los datos sensibilidad y el conocimiento humano, da mejor resulta en la combinación de las dos fuentes de información.

Se construye un modelo general utilizando una red neuronal para todos las muestras no tejidas. Caracteriza la relación entre los parámetros estructurales seleccionados y el propiedad funcional correspondiente. Por la propiedad de permeabilidad al agua, utilizando la clasificación basada en lógica difusa método, tomamos las cinco estructuras más relevantes parámetros como variables de entrada públicas.

Se construye un modelo especial para la familia de no tejidos materiales producidos utilizando una tecnología de unión específica (enlace químico). Su arquitectura y parámetros son construido en base al modelo general correspondiente. Los La tasa de enlace se agrega al conjunto de las variables de entrada de el modelo general. La muestra el modelo especial construido para predecir la permeabilidad del agua con cinco públicos parámetros (peso base, espesor, densidad de la fibra, total uniformidad del volumen de poros y del peso base) como entrada variables. El parámetro estructural especial (tasa de aglutinante) luego se agrega al conjunto de estas cinco variables de entrada.

En esta aplicación, el modelo general se basa en 18 muestras de tres familias de productos. Cada familia es compuesto por 6 muestras. Usamos el dejar uno fuera técnica para probar la efectividad del modelo general y el modelo especial. Esta técnica se describe como sigue. Realizamos 18 pruebas. En cada prueba, eliminamos una muestra de la base de aprendizaje para probar el modelos. Las muestras restantes se utilizan para aprender el modelo general y las 5 muestras restantes del la familia correspondiente se utiliza para aprender el especial modelo. A continuación, para la muestra de prueba, calculamos el diferencia entre el valor real del agua permeabilidad, la salida del modelo general y la Salida del modelo especial. Este procedimiento se repite 18 veces para que todas las muestras se puedan extraer de la base de aprendizaje para probar los modelos.

Según, el número de datos de aprendizaje relacionadas con 5 variables de entrada no debe ser menor que. Luego, la técnica de dejar uno fuera con aprendizaje Los datos permiten obtener resultados eficientes en general. modelo.

La da los detalles de los resultados experimentales en la permeabilidad al agua y la correspondiente predicción resultados obtenidos del modelo general y del especial modelo. La compara el predicho y el valores experimentales de la permeabilidad al agua obtenidos de los modelos generales y especiales y los reales medidas físicas, respectivamente.

En este experimento, encontramos que la ANN propuesta Los modelos dan resultados satisfactorios con valores bajos de error de predicción promedio, a pesar de la cantidad restringida de datos.

De estos resultados experimentales, podemos ver que el modelo especial da errores de predicción más bajos (promediado error: 1,60%) que el modelo general (error promedio: 6,55%). Esta observación se puede explicar de la siguiente manera:

1. El modelo general utiliza muestras de varias familias que se diferencian entre sí en muchos aspectos mientras que el modelo especial solo usa muestras de la misma familia. La especificidad de cada familia no puede ser tenida en cuenta en el modelo general.
2. El modelo especial se construye basándose en el mismo estructura como modelo general. Solo los pesos conectar la entrada específica a las neuronas ocultas son introducido. Entonces, tiene en cuenta tanto la especificidad de cada familia de productos y la generalidad de todas las familias.

4. Conclusión

En este trabajo se propone un sistema de apoyo para optimizar el diseño de productos no tejidos, en de acuerdo con las especificaciones. La relación entre parámetros estructurales y propiedades funcionales de productos no tejidos se modela utilizando neuronas artificiales redes. Para reducir la complejidad del modelos y resolver la dificultad de insuficiente disponibilidad datos, se seleccionan los parámetros estructurales más relevantes según la sensibilidad de los datos y el conocimiento humano conformidad. Un criterio de selección basado en lógica difusa es desarrollado para encontrar el mejor compromiso entre estas dos fuentes de información. La selección procedimiento de parámetros estructurales permite a los diseñadores centrarse en los parámetros más relevantes para realizar experimentos de producción relacionados con el nuevo producto. En el procedimiento de modelado, se definen dos modelos. En primer lugar, se desarrolla un modelo general para todos familias de productos. Está construido a partir del conjunto de públicos variables de entrada. Luego se construye un modelo especial para cada familia de productos agregando estructuras especiales parámetros al conjunto de variables de entrada públicas. los La simulación de estos modelos permite a los diseñadores optimizar estructura de materiales y minimizar el número de experimentos.

El método propuesto se ha aplicado con éxito a la industria de no tejidos para predecir tres funcionales propiedades: permeabilidad al agua, resistencia a la rotura y alargamiento en el pico en la dirección de la máquina. La simulación Los resultados muestran errores de predicción bajos tanto para el general y los modelos especiales. En nuestro trabajo futuro, este El procedimiento de modelado se puede mejorar aún más encontrando nuevos métodos para procesar las

restricciones existentes, como pequeña cantidad de datos, interdependencias entre parámetros estructurales e integrar el conocimiento humano sobre procesos y productos.

Referencias

- [1] Shanmugasundaram, O.L., Syed Zameer Ahmed, K., Sujatha, K., Ponnmurugan, P., Srivastava, A., Ramesh, R., Sukumar, R., Elanithi, K. "Fabrication and characterization of chicken feather keratin/polysaccharides blended polymer coated nonwoven dressing materials for wound healing applications", (2018) *Materials Science and Engineering C*, 92, pp. 26-33.
- [2] Çinçik, E., Yildiz, S.C., Yildirim, Ö. "The effect of repeated laundering on properties of needled and calendered nonwoven cleaning materials produced with different process conditions", (2017) *Tekstil ve Konfeksiyon*, 27 (1), pp. 60-67.
- [3] Bolbasov, E.N., Stankevich, K.S., Sudarev, E.A., Bouznic, V.M., Kudryavtseva, V.L., Antonova, L.V., Matveeva, V.G., Anissimov, Y.G., Tverdokhlebov, S.I. "The investigation of the production method influence on the structure and properties of the ferroelectric nonwoven materials based on vinylidene fluoride – tetrafluoroethylene copolymer", (2016) *Materials Chemistry and Physics*, 182, pp. 338-346.
- [4] Xie, S., Han, W., Jiang, G., Chen, C. "Turbulent air flow field in slot-die melt blowing for manufacturing microfibrinous nonwoven materials", (2018) *Journal of Materials Science*, 53 (9), pp. 6991-7003.
- [5] Özen, İ., Okyay, G., Ulaş, A. "Controlled fertilizer release via tunable poly(vinyl alcohol)/ammonium sulfate-coated nonwoven materials", (2019) *Journal of Coatings Technology and Research*, 16 (1), pp. 93-102.
- [6] Zhang, L., Zhang, X. "Study on properties of needle-punched nonwoven fabric used as building insulation material", (2019) *Fangzhi Gaoxiao Jichukexue Xuebao*, 32 (1), pp. 12-16.
- [7] Rawal, A., Sharma, S., Kumar, V., Rao, P.V.K., Saraswat, H., Jangir, N.K., Kumar, R., Hietel, D., Dauner, M. "Micromechanical analysis of nonwoven materials with tunable out-of-plane auxetic behavior", (2019) *Mechanics of Materials*, 129, pp. 236-245.
- [8] Malakhov, S.N., Chvalun, S.N. "Multifunctional nonwoven materials, produced by electrospinning of a heated solution and melt of ethylene-octene copolymer", (2019) *Materials Today Communications*, 21, art. no. 100729.
- [9] Cubric, G., Salopek Cubric, I. "Study of Grippers in Automatic Handling of Nonwoven Material", (2019) *Journal of The Institution of Engineers (India): Series E*, 100 (2), pp. 167-173.
- [10] Brochocka, A., Nowak, A., Panek, R., Franus, W. "The effects of textural parameters of zeolite and silica materials on the protective and functional properties of polymeric nonwoven composites", (2019) *Applied Sciences (Switzerland)*, 9 (3), art. no. 515.
- [11] Cha, J.-H., Ahn, S.-J., Jeon, H.-Y. "Manufacturing of nonwoven fabrics containing porous inorganic materials and the evaluation of their cesium adsorption performance", (2018) *Polymer (Korea)*, 42 (2), pp. 339-346.
- [12] Gu, J., Xiao, P., Chen, P., Zhang, L., Wang, H., Dai, L., Song, L., Huang, Y., Zhang, J., Chen, T. "Functionalization of Biodegradable PLA Nonwoven Fabric as Superoleophilic and Superhydrophobic Material for Efficient Oil Absorption and Oil/Water Separation", (2017) *ACS Applied Materials and Interfaces*, 9 (7), pp. 5968-5973.
- [13] Claramunt, J., Fernández-Carrasco, L.J., Ventura, H., Ardanuy, M. "Natural fiber nonwoven reinforced cement composites as sustainable materials for building envelopes", (2016) *Construction and Building Materials*, 115, pp. 230-239.
- [14] Hong, J., Jiang, S., Yan, X. "Sound absorption properties of HXNBR/FHHPF composite with needle-punched hollow polyester nonwoven laminated materials", (2016) *Industria Textila*, 67 (6), pp. 365-374.