

# Designing Predictive Tools for Personalized Functionalities in Knitted Performance Wear

Developments of advanced textile manufacturing techniques —such as 3D body-forming knitwear machinery— allows the production of almost finalized garments, which require little to no further production steps to finalize the garment. Moreover, advanced knitting technology in combination with new materials enables the integration of localized functionalities within a garment on a “stitch by stitch level.” There is potential in enhancing the design tools for advanced knitting manufacturing through the use of technologies such as data gathering, machine learning, and simulation. This approach reflects the potential of Industry 4.0, as design, product development, and manufacturing are moving closer together. However, there is still limited knowledge at present about how these new technologies and tools can have an impact on the creative design process. The case study presented in this paper explores the potential of predictive software design tools for fashion designers who are developing personalized advanced functionalities in textile products. The main research question explored in this article is: “How can designers benefit from intelligent design software for the manufacturing of advanced personalized functionalities in textile products?”. Within this larger research question three sub-research questions are explored: <sup>(1)</sup> What kind of advanced functionalities can be considered for the personalization process of knitwear? <sup>(2)</sup> How to design interactions and interfaces that use intelligent predictive algorithms to stimulate creativity during the fashion design process? <sup>(3)</sup> How will predictive software impact the manufacturing process for other stakeholders and production steps? These questions are investigated through the analysis of a Research Through Design case study, in which several predictive algorithms were compared and implemented in a user interface that would aid knitwear designers during the development process of high-performance running tights.

## 1 INTRODUCTION

Developments of advanced textile manufacturing techniques —such as 3D body-forming knitwear machinery— allow the production of almost finalized garments, which require little to no further production steps to finalize the garments (Sayer, Wilson, and Challis 2006). Moreover, advanced knitting technology in combination with new materials enables the integration of localized functionalities within a garment on a “stitch by stitch level,” such as moisture management, compression, and abrasion resistance (Power 2018). This is done, for example, by using areas in the garment where elastane

(spandex) is inserted to create more stretchable surfaces to almost form a “second-layer” on the skin (Vasconcelos et al. 2013). These types of new functional properties within garments, offered by both materials and developments of manufacturing technologies, force a conceptual shift in the way garments are both designed and created. Knitted constructions provide remarkable diversity and a range of potential end products, however, currently the market is not fully able to absorb and utilize the technological advances (Black 2002). One of the possible reasons for this problem is that the advanced knitting machines capable of producing high-value functional apparel require highly skilled programmers and designers with technical understanding. Knitwear is inherently difficult to describe, as

M. TEN BHÖMER ET AL.

43

### KEYWORDS

Knitwear, Interaction Design, Industry 4.0, Machine learning, Artificial Intelligence, Interface Design, Circular Knitting.

### HOW TO CITE

Ten Bhömer, Martijn, Hai-Ning Liang, Difeng Yu, Yuanjin Liu, Yifan Zhang, Eva de Laat, and Carola Leegwater. 2019. “Designing Predictive Tools for Personalized Functionalities in Knitted Performance Wear”. *Temes de Disseny* 35: 42-75.

CASE STUDY

42

MARTIJN TEN BHÖMER  
HAI-NING LIANG  
DIFENG YU  
YUANJIN LIU  
YIFAN ZHANG  
Xi'an Jiaotong-Liverpool University

EVA DE LAAT  
CAROLA LEEGWATER  
Studio Eva x Carola

TEMES DE DISSENY #35



no simple and complete notation exists. The relationship between the visual appearance and structure and technical properties of a knitted fabric is subtle and complex (Eckert 2001). This is an area that has been traditionally problematic within the knitting sector. Understanding between technologists and designers is hindered which limits the possibility of dialogues from which design innovation can emerge (Power 2018).

Recently, there has been interest from the Human-Computer Interaction (HCI) community to narrow the gap between product design, technology, and knitwear, for example, by developing a compiler that can automatically turn assemblies of high-level shape primitives and even 3D models into low-level machine instructions (McCann et al. 2016). In the field of Computer Science, there have been instances where techniques such as data mining and machine learning were applied to aid the design process of complex garment manufacturing (Yildirim, Birant, and Alpyildiz 2018). This led to advantages such as better prediction of parameters, for example, fabric elongation (Ogulata et al. 2006), comfort (Li et al. 2009), and air permeability (Matusiak 2015). Another benefit is enhanced sustainability due to reduced consumption of textile-related materials such as fabrics, yarns, dyes, and sewing threads (Jaouachi and Khedher 2015). Better sizing could be achieved by analyzing textile data, leading to improved customer satisfaction (Hsu and Wang 2005). Another approach for applying technical advancements to specialized knitwear design can be found in offering better simulation possibilities, which could lead to the reduction of the number of iteration cycles for knitting material samples, especially when manufacturing highly varied designs (Karmon et al. 2018). These types of opportunities are further considered in industry paradigms such as the German strategic initiative “Industrie 4.0” (Kagermann, Wahlster, and Helbig 2013). Within Industry 4.0, concepts such as production for high diversity, personalization on demand, and distributed and local manufacturing are becoming a reality (Lasi et al. 2014). The design profession has an opportunity to create methods and tools for the various stakeholders to support the Industry 4.0 process. This includes the development of novel digital tools and human-computer interaction solutions that enable people to be integrated into the cyber-physical structure in such a way that their individual skills and talents can be fully realized (Gorecky et al. 2014).

There is potential in enhancing the design tools for advanced knitting manufacturing through the use of technologies such as data gathering, machine learning, and simulation. This approach reflects the potential of Industry 4.0, since design, product development, and manufacturing are moving closer together. However, currently there is still limited knowledge about how these new technologies and tools can have an impact on the creative design process. Therefore, the case study presented in this paper will explore the potential of predictive software design tools for fashion designers who are developing personalized advanced functionalities in textile products. The main research question explored in this article is: “How can designers benefit from intelligent design software for the manufacturing of personalized advanced functionalities in textile products?”.


Within this larger research question three sub-research questions are explored: (1) What kind of advanced functionalities can be considered for the personalization process of knitwear? (2) How to design interactions and interfaces that use intelligent predictive algorithms to stimulate creativity during the fashion design process? (3) How will predictive software impact the manufacturing process for other stakeholders and production steps? These questions are investigated through the analysis of a Research Through Design case study, in which several predictive algorithms were compared and implemented in a user interface that would aid knitwear designers during the development process of high-performance running tights.

2  
CASE STUDY: FUNCTIONALITIES FOR CIRCULAR KNITWEAR


The design process of knitwear garments consists of several sequential steps, requiring multiple translations between different media (such as sketches, patterns, and machine code) and between different people (fashion designer, knitwear designer, knitting engineer, and machine technician). Fig. 1 shows the development process of a (smart) knitted dress, produced during a project done in The Netherlands (ten Bhömer, Jeon, and Kuusk 2013). Designers often work with 2D graphic design software, which is transformed by knitting engineers using advanced knitting engineering software into machine instructions, which is finally manufactured by the technician on industrial knitting machines. The final result can only be evaluated by the designer and wearer after the manufacturing (the red backwards arrow in Fig. 1). Therefore, the integration of specialized functionalities (such as compression, breathability of the textiles, and areas used for sensing vital signs) require many cycles of product development and manufacturing.

This leads to a challenge because in the design process it is often beneficial to be able to have rapid iterations in which potential directions can be explored and evaluated. In the case of knitwear, we have previously attempted to bridge this gap using prototyping techniques such as on-the-body paper prototyping and 3D printing (ten Bhömer, Canova, and de Laat 2018). However, one of the limitations of this approach was that the design of knitted garments often goes beyond shapes and visuals and moves into the domain of material properties such as compression and breathability. Furthermore, advanced design software exists that offers designers virtual sampling possibilities so garments can be designed and evaluated virtually, without manufacturing (Shima Seiki, n.d.).


However, in most of these cases the software focuses on visual and shape properties only, and not on functional requirements of the garments. In this project we hypothesize that knitwear designers can have increased creative freedom when they have direct feedback about the intended functionalities during the design process (without actual manufacturing). This was the starting point of a case study that we conducted within the knitwear industry. In



1. Fashion designer sketches design




4. Fashion designer transforms design into digital bitmap



2. Textile engineer creates knitting pattern



5. Knitting technician sets yarn tensions and other machine parameters



3. Fabric produced by machine



6. Designer test whether the fabric meets desired requirements


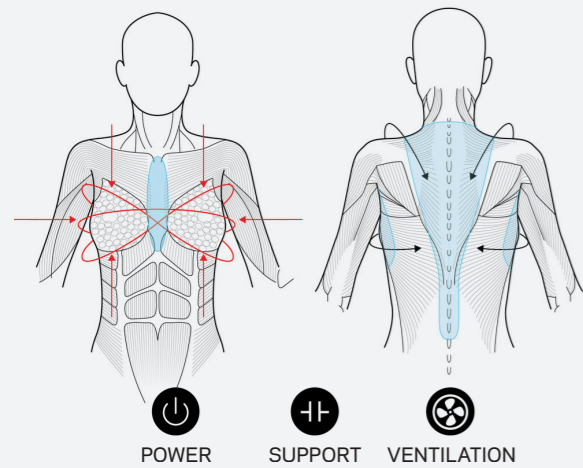


Fig. 1. Overview of the steps normally taken in the design process of garments (photos by CRISP project, Eindhoven University of Technology). In this particular project a flatbed knitting machine was used, in contrast to circular knitting machines which were used in this article.



## ANALYSIS FUNCTION MAPPING



### Anatomy considerations

▨ Muscle identification

▨ Fat, ligaments and connective tissue

### Stretch considerations

- A compression fit that restricts breast movements  
→ high compression
- Direction of body correction → support at shoulders & spine

### Ventilation considerations

▨ Focused cooling zones to maintain body's core temperature



Fig. 2. Example project of seamless knitwear designed by the knitwear design team in the project, manufactured using circular knitting machines. The sports bra has several different functional textures combined; 1) Open structures for breathability; 2) rigid zones for posture correction; 3) Textured structures for airflow; and 4) Tighter and looser stitch zones to create comfort and stretch vs rigid areas. The bra is a garment that is, by nature, extremely personal. It can vary in many ways, not just in function, size, and style, but also in terms of how it's worn and the type of support it needs to offer. Images and project by Studio Eva x Carola.





Fig. 3. Example of pattern files that represent the knitting machine instructions. The colors on the pattern in the left represent the different material or surfaces as described by the designer. The pattern on the right represents the different knitting structures that the machine has to make (each pixel represents a stitch by the needle).

this project, several partners were involved: a team with a background in Industrial Design (focusing on the application, testing of fabric samples, and user interface design), a team with a background in Computer Science (focusing on the implementation of Machine Learning algorithms as well as the realization of an interactive prototype), and a team with a background in knitwear design (focusing on the requirements of the software tool, providing knowledge on knitting processes, and manufacturing of the physical samples).

### 2.1. Circular Knitwear

This project focusses exclusively on *functionalities* in knitted garments. More precisely, we focus on a specific type of knitting called *circular knitting*. The term circular covers all knitting machines whose needle beds are arranged in circular cylinders and can knit a wide range of fabric structures, garments, hosiery, and other articles in a variety of diameters (Spencer 2001). Circular knitting is usually contrasted with flatbed knitting, where the yarn is moved across a horizontal needle bed. 3D seamless knitting machinery allows the creation of virtually finished garments directly from the machine (Sayer, Wilson, and Challis 2006). Within the development of flatbed knitting machines the two major machine manufacturers *Shima Seiki* and *Stoll GmbH* have both created their own versions of this technology, named *Wholegarment* and *Knit and wear* respectively. Seamless constructions within circular knitting machines

have developed from the hosiery tradition, led through the creation of body sized circular machinery adapted from the small diameter hosiery machines, such as those produced by Santoni (Black 2002). Circular knitting technology has evolved and enables designers to create sleek bodywear and performance active wear (Fig. 2). It allows ready-to-wear three-dimensional (3D) tubular garments to be created directly from yarns without any seams, for example in underwear, swimwear, and sportswear (Lau and Yu 2016).

### 2.2. Functionalities for Running

To help decision making in the project we decided to choose a type of product which is quite common in the context of circular knitted garments, but which has considerable design challenges because the functionalities are hard to predict during the design phase. Running tights represent such a product. Running is a complex, coordinated process which involves the entire body, since it has as a main characteristic that both feet are off the ground at the same time. Based on distance, there are different types of running sports: sprints, middle distance, and long distance. Within sprints, the common distances are 60m, 100m, 200m, and 400m. Therefore, athletes need to summon enormous strength within a short time which puts a lot of stress on muscles, especially in the legs. For example, the quadriceps muscle stabilizes the knee against forward collapse, while the hamstrings and gastrocnemius prevent extension and tibial rotation (Slocum and James 1968). Based on this

knowledge about the biomechanics of running, it can be concluded that different parts of the garment worn by the sprinter have different functional needs.

### 2.3. Machine Learning

This project aims to predict the functionalities of a manufactured fabric product, without the need of actually producing the product. To this end, one of the most popular and powerful approaches is machine learning. Machine learning enables us, with the help of computers, to predict certain outcomes or new samples by “training” mathematical models using example data or past experience (Alpaydin 2014). The trained model can generate accurate predictions or decisions without being explicitly programmed to perform the task (Bishop 2006). Because of its usefulness, machine learning has been widely applied in many domains such as healthcare, fraud detection, personalized recommendations, etc. In this project, we consider multiple machine learning techniques including linear, non-linear, and tree-based models to predict various target variables collected from empirical testing. We will follow three general steps when applying machine learning algorithms: 1) data collection and preparation; 2) model building, evaluating, and selecting; 3) prediction (Kuhn 2013).

### 2.4. Article Structure

Section 3 describes how we build the data model by selecting important *target variables* and *predictor variables* that function as the basis of the predictive software. Section 4 continues with the process of *data collection and preparation*, which includes the development and manufacturing of physical samples as well as testing procedures to create a data set. In Section 5, *we build, evaluate, and select the machine learning models*—several algorithms are compared based on their ability to predict the target variables. Section 6 shows the development of a prototype of the User Interface which allows the knitwear designers to receive real-time feedback from the Machine Learning algorithms. In Section 7, important findings that became apparent during the project are described. Finally, in Section 8 we conclude with a reaction to the initial research questions.




Fig. 4. The plain stitch (a) and three different stitch types in our data model: (b) knit stitch; (c) float stitch; (d) tuck stitch. Figures adapted from (Spencer 2001).




Fig. 5. Float knitted stitches distributed in the horizontal direction of a knitted fabric: (a) plain stitch; (b) 1 x 1 float; (c) 1 x 2 float; (d) 1 x 3 float. Figures adapted from (Liu et al. 2016).

The goal of the data model is to connect previous information about the design of the fabric, with the functional properties of the actually manufactured knitted product. In our data model we express these two parts using predictor variables (the parameters that potentially have an impact on the result) and the target variables (the desired outcomes).

### 3.1. Predictor Variables

The main property of circular knitting technology is that all the constructions are restricted by a tubular shape. Variations in shape and functionality can be realized by making changes in the materials (the yarns) and structures (the specific knits) within this tube (Matkovic 2010). These variations are normally expressed using patterns which can be converted in machine-readable instructions (Fig. 3 shows an example of these types of patterns).

In order to simplify the data model for the first trial of our approach, we decided to limit the variation of materials and instead focus on the combination of different knitting structures. For the materials we chose to use two basic yarns which are commonly used in sports garments: elastane yarn (made from a synthetic fiber known for its exceptional elasticity) and nylon yarn. As shown in Table 1, to make variations of the knitting structures we defined three parameters that would serve as the predictor variables: *stitch type*, *stitch structure*, and *tube coverage*.

#### Stitch type

For the variations in structures we chose three basic stitch types: *miss*, *float*, and *tuck* (Spencer 2001). Before introducing the differences between these three different stitch types, it is helpful to introduce the *plain stitch*, which is the most fundamental knitting stitch that can be considered as the basic unit of intermeshing. It usually consists of three or more intermeshed needle loops (Fig. 4a). It forms the base structure of ladies’ hosiery, fully fashioned knitwear, and single-jersey fabrics. The *miss stitch* (Fig. 4b)

Stitch type	Stitch structure	Tube coverage
Miss	1 x 1	25%
Float	1 x 2	50%
Tuck	1 x 3	75% 100%

Table 1. Overview of the chosen predictor variables.

—sometimes called *floating stitch*— is produced when a needle holding its old loop fails to receive the new yarn that passes, as a float loop, joining together the two nearest needle loops knitted from it. The float stitch (Fig. 4c) —also referred to as *float plating*— produces an open-work mesh structure in a single jersey and involves feeding two yarns in a plating relationship. The structure has been used for run-resistant fabric in stockings, textured designs, and underwear mesh structures. The *tuck stitch* (Fig. 4d) is formed when a knitting needle holds its old loop and then receives a new yarn. The previously formed knitted loop is called the held loop and the loop which joins it is a tuck loop.

#### Stitch Structure

Another important variable that can predict the final functionality and performance of the fabric is the structure that is created with the stitch types. The structure determines the size of the special stitch in the fabric. For example, a 1 x n float structure is composed of one integrated knit loop stitch and n float stitches. For reference, Fig. 5a shows a plain knit structure and three varieties for the float stitch: 1 x 1 float (Fig. 5b), 1 x 2 float (Fig. 5c), and 1 x 3 float (Fig. 5d). To limit the complexity of our dataset, we did not include any stitch structures larger than 1 x 3. When knitting a fabric, each individual knit type can be combined with different knit structures in order to create specific functions. For example, creating a larger stitch structure of tuck stitches will create an open structure, simultaneously widening the circumference of the resulting tube.

#### Tube Coverage

The third prediction variable is the coverage of the stitch structure within the knitted fabric tube. A garment can be built up from various structural areas, which play an important role to define the functionality. For example, a sports shirt could have compression around the triceps to help with recovery of the muscles and at the same time the armpits could have an open structure for heat management during a workout. To limit complexity, we decided that in each fabric we can only combine one specific stitch type with a plain knitting stitch. Additionally, instead of allowing various shapes to be created in the fabric we decided to only work with a rectangular area of a specific stitch type and structure. We simplified these structural variabilities further by choosing four different designs of the tubular structure of the fabric: 25%, 50%, 75%, and 100% (as seen in Fig. 6). For example, a coverage of 25% of the 1 x 1 float structure means that

25% of the surface of the knitted tube is covered with the 1 x 1 float, and the other 75% is knitted with a regular plain knitting stitch.

### 3.2. Target Variables

Compression garments refer to tight and compressive forms of clothing that can be made out of elastane and nylon, and are widely used by athletes and gym users during sports activities. The primary purpose for athletes is to provide the ability of recovery and also the improvement of performance (Hill et al. 2014). Although research is still inconclusive, it has been suggested that compression garments may improve joint awareness, local blood flow, waste product removal, improve running economy, reduce swelling, reduce muscle oscillations, and decrease post-exercise muscle soreness (Born, Sperlich, and Holmberg 2013). Thus, the clothes athletes wear should have good performance with functionalities such as compression, comfort, recovery, wicking, breathability, air permeability, and so on. Therefore, the target variables that the designer of these types of clothing would like to evaluate are related to functionalities provided by compression clothing. We considered several functionalities during the process:

1. Wicking (measured by using the vertical wicking test, how far water can move through a vertical hanging piece of fabric)
2. Chafing (measured by using the coefficient of friction test, angled slope to measure the force necessary for a weight to slide over the fabric)
3. Absorption (by measuring the speed of water absorption)
4. Permeability (measured by using the upright cup method, using the textile as a membrane to see how much water collects in a cup)
5. Insulation (could be measured using heated hot-plate or thermal mannequin)
6. Compression (measured through testing the elongation of the fabric when pulling a certain weight)
7. Subjective comfort (measured by using validated questionnaires and scales to evaluate the feel of the fabric)

Finally, we came to a list of target variables summarized in Table 2. Choosing the target variables was a trade-off between the testing capabilities and Lab facilities and setting a priority for the most important functionalities.




Fig. 6. Variations in tubular coverage as indicated by the percentages.

Basic parameters	Dynamic parameters	Performance Index
Weight <sup>a</sup> Garment Diameter <sup>b</sup>	Unload Force <sup>b</sup> Elongation <sup>a,b</sup> Evaporation <sup>a</sup>	Power Index <sup>b</sup> Comfort Index <sup>b</sup> Energy Index <sup>b</sup>

Table 2. Overview of the chosen target variables. Variables with <sup>a</sup> have been tested internally in our own Lab. Target variables indicated with <sup>b</sup> were tested in an external Lab.



### Basic parameters

The basic parameters can help designers to evaluate the basic properties of the designed fabric for the garment. Since each fabric will have different properties due to differences in knitting stitch, structure, and coverage, the designer normally doesn't have a precise insight into the properties of the final manufactured product. Weight and the diameter of the fabric tube are two main variables that we chose as target.

### Dynamic parameters

Compression garments can decrease symptoms related to muscle damage through mechanical support to the injured tissue and a reduction in motion of the limb. The *unload force* variable will define how much energy is exerted to the body by the garment. Whether the constant pressure is successfully maintained on the human body depends mainly on the elasticity of the compression garment, which can be measured through the *elongation* target variable. Physiological comfort is further affected by the rate of moisture transport within the textile. It can be uncomfortable for the wearer when perspiration exceeds the absorption capability. Therefore, *evaporation* was selected as the target variable to evaluate this function.

### Performance Index

To compare our own target variables, we used a third category of target variables, which were provided by a proprietary testing partner. The Performance Index is a supply chain tool that can help communication between different stakeholders as it promises an objective quantitative scale for various fabric parameters (INVISTA Apparel & Advanced Textiles 2017). The Performance Index consists of three measurements: *Power Index*, *Energy Index*, and *Comfort Index*. Power Index measures the performance factor of fabrics on a scale of one to ten. The Comfort Index measures their "second skin" ability to deliver close-fitting freedom of movement. The Energy index rates the energy absorbed by moving in the garment.

4

## DATA COLLECTION AND PREPARATION

In order to train the machine learning algorithms, it was necessary to create a dataset which the algorithms could use to base the predictions on. Creating this training data consisted of two steps. First, it was necessary to create physical samples of fabric with different predictor variable combinations. Second, it was necessary to devise a set of testing protocols to evaluate the performance of the target variables within these samples.

### 4.1. Fabricating the fabric samples

We used circular knitting machines to knit 36 tubular fabric structures (a single tubular structure is shown

in Fig. 7) which cover all the variations of different predictor variables (Table 3 shows all the combinations while Table 4 shows all the physical samples ordered by variation).

### 4.2. Testing the fabric samples

Before testing the elongation and evaporation, the *weight<sup>a</sup>* of each sample was measured first. An electronic scale was used to measure the fabric samples. To measure the *elongation<sup>a</sup>*, a one kilogram pulling force was attached to the tubular samples. The elongation was recorded by a ruler, and the amount of change was calculated by dividing the initial length by the elongated length. To measure *evaporation<sup>a</sup>*, one milliliter of distilled water was sprayed on the target area of the garment and evaporation time was recorded as the results. Especially during this test, it became clear that the measurement of a localized functionality (evaporation) was hard to generalize for the full fabric tube. For example, when measuring the evaporation on the 1 x 2 tuck (50% coverage) fabric, the evaporation value could be very different on the plain knit part of the fabric compared to the value on the 1 x 2 tuck part. Therefore, we decided to calculate the evaporation value for each tube, based on the proportion. For example, for the previously mentioned tube of 1 x 2 tuck (50 % coverage) we measured 12 minutes for the water to evaporate from the plain knit, and 8 minutes for the area with the 1 x 2 tuck knit. In this case the proportional value became 10 minutes ( $12 * 0.5 + 8 * 0.5$ ). The target variables *elongation<sup>b</sup>*, *garment diameter<sup>b</sup>*, *unload force<sup>b</sup>*, and the three Performance Index variables (*Power Index<sup>b</sup>*, *Energy Index<sup>b</sup>*, *Comfort Index<sup>b</sup>*) were measured in an external lab following proprietary measurement methods. An overview of all the test results can be found in Table 5.

5

## MACHINE LEARNING MODEL BUILDING, EVALUATION, AND SELECTION

In order to model the relation between the predictors and target variables, we compared a set of eight algorithms. These algorithms can be divided into three groups: linear regression models, non-linear regression models, and tree-based models. Linear models make a prediction by using a linear function of the predictors. They are simple and more interpretable but might have limited power in handling complex datasets. The three linear models we tested were: *Linear Regression*, *Robust Linear Regression*, and *Elastic Net*. Non-linear models are more powerful since they can fit more types of curves than linear relationships, but are generally less interpretable and harder to train. We tested the following non-linear models: *Multivariate Adaptive Regression Splines (MARS)*, *Neural Network*, and *Support Vector Machine (SVM)*. Tree-based models are among the most popular models in machine learning since they are easy to use and able to capture complex non-linear relationships. As a disadvantage, they might be prone to memorizing the noise present in a dataset. The tree-based algorithms we tested were: *Random Forests* and *Boosted Trees*. We applied different pre-processing techniques for

Table 3. Overview of the 36 samples that were knitted.

		Tube Coverage			
		25 %	50%	75%	100%
Stitch type	Stitch structure	ID	ID	ID	ID
Float	1*1	1	2	3	4
	1*2	5	6	7	8
	1*3	9	10	11	12
Miss	1*1	13	14	15	16
	1*2	17	18	19	20
	1*3	21	22	23	24
Tuck	1*1	25	26	27	28
	1*2	29	30	31	32
	1*3	33	34	35	36

→ Fig. 7. Appearance of one of the tubular structures (1 x 3 Float, 25% coverage).  
↓ Table 4. Overview of the 36 samples ordered by variation.



	Stitch Structure	Stitch Type											
		Tuck				Miss				Float			
		25%	50%	75%	100%	25%	50%	75%	100%	25%	50%	75%	100%
Stitch Structure	1 x 1												
	1 x 2												
	1 x 3												



ID	Predictor Variables			Target Variables								
	Stitch Type	Stitch Structure	%	Lab test results			External test results					
				Weight <sup>a</sup>	Elongation <sup>a</sup>	Evaporation <sup>a</sup>	Power index <sup>b</sup>	Comfort index <sup>b</sup>	Energy index <sup>b</sup>	Unload force <sup>b</sup>	Enlongation <sup>b</sup>	Garment diameter <sup>b</sup>
1	1	1	0.25	130.7	0.17	12.25	2	7	5	596	246	34.5
2	1	1	0.5	133.3	0.17	13.5	2	7	5	656	225	33.5
3	1	1	0.75	123.1	0.16	14.5	2	7	4	658	232	
4	1	1	1	107.5	0.20	16	2	7	5	640	231	32
5	1	2	0.25	135.2	0.14	12.5	2	7	4	628	201	34
6	1	2	0.5	128	0.20	15	2	7	4	665	190	33.2
7	1	2	0.75	114.8	0.30	17	2	7	4	693	186	31.5
8	1	2	1	92.5	0.19	20	2	7	4	687	189	30.5
9	1	3	0.25	138.5	0.25	6.25	2	7	4	618	179	35
10	1	3	0.5	124.3	0.21	7.5	2	6	5	674	165	33
11	1	3	0.75	110	0.24	8.5	2	7	4	716	163	32
12	1	3	1	96.1	0.24	10	2	7	4	678	169	30.8
13	2	1	0.25	145.6	0.16	15.5	2	5	10	850	149	34.6
14	2	1	0.5	138.5	0.13	15	2	5	10	846	144	34.7
15	2	1	0.75	131.4	0.20	14.6	3	5	9	911	141	33.5
16	2	1	1	120.8	0.15	14	3	5	9	910	140	33
17	2	2	0.25	142	0.16	15.5	2	5	10	950	123	35
18	2	2	0.5	132.6	0.21	16	3	4	10	987	120	33
19	2	2	0.75	124	0.18	16.4	3	5	10	980	123	32
20	2	2	1	115.1	0.12	17	3	5	10	991	119	31.7
21	2	3	0.25	140	0.21	14.5	2	5	10	880	132	33.5
22	2	3	0.5	130.9	0.20	15	3	5	10	951	125	32
23	2	3	0.75	120.8	0.16	15.4	2	6	9	893	136	29.2
24	2	3	1	111.4	0.13	16	3	5	10	922	131	28.2
25	3	1	0.25	168.6	0.15	10.5	3	8	4	813	183	38
26	3	1	0.5	167.8	0.15	10	3	8	4	850	176	40.5
27	3	1	0.75	170	0.22	9.6	3	8	4	854	179	42.5
28	3	1	1	167.8	0.17	9	3	8	4	855	177	44
29	3	2	0.25	167.7	0.22	11	2	4	10	981	132	38.5
30	3	2	0.5	165.8	0.14	10	2	4	10	1002	132	41
31	3	2	0.75	165.9	0.12	9.2	2	4	10	983	133	43.7
32	3	2	1	165.9	0.11	8	2	4	10	997	132	47
33	3	3	0.25	167.6	0.23	9.75	2	4	10	1004	128	39
34	3	3	0.5	166.5	0.18	9.5	2	3	10	1122	117	41.5
35	3	3	0.75	165.1	0.11	9.3	2	3	10	1145	116	45.5
36	3	3	1	164.7	0.11	9	2	3	10	1146	117	48

Table 5. Overview of the test results

Category	Algorithm	Pre-processing
Linear Model	Linear Regression Robust Linear Regres. Elastic Net	Centering, Scaling Centering, Scaling Cent., Scaling, Box-Cox Transformation
Non-linear Model	MARS Neural Network Support Vector Machine	- Centering, Scaling Centering, Scaling
Tree-based Model	Random Forest Boosted Trees	- -

Table 6. A summary of the machine learning models and pre-processing techniques

the above algorithms according to Kuhn et al. (2013), as summarized in Table 6.

Two methods for measuring the effectiveness of the algorithms are RMSE (root-mean-square error) and R<sup>2</sup> (coefficient of determination). RMSE is the quadratic mean of the differences between values predicted by a model and the value actually observed. It is frequently used as a measure of accuracy, to compare forecasting errors of different models on a particular target variable. R<sup>2</sup> is another metric we applied to evaluate the algorithms, as it can be interpreted as the

proportion of the information in the data that can be captured by the model. As a measurement of correlation, R<sup>2</sup> has the advantage of being scale-free. That is, it does not matter if the scale of the target outcome is large or small; the value of R<sup>2</sup> will range from 0 to 1. Normally, lower RMSE and higher R<sup>2</sup> indicate the model is a good fit for the target variable.

We built the eight models introduced above and evaluated them in two sets of analysis; first with the data generated from the tests in our own lab (*Weight<sup>a</sup>, Elongation<sup>a</sup>, Evaporation<sup>a</sup>*), and in a second analysis with the data

provided by the external testing lab (*Power Index<sup>b</sup>, Comfort Index<sup>b</sup>, Energy Index<sup>b</sup>, Unload Force<sup>b</sup>, Elongation<sup>b</sup>, and Garment Diameter<sup>b</sup>*). After that, we selected the final models.

### 5.1. First analysis

In this first test, we tuned the models and evaluated their performance through five repeats of 10-fold cross-validation (Kuhn et al. 2013). Cross-validation is a technique to estimate a model's performance by partitioning the original sample into a training set to train the model, and a validation set (also called the holdout set) to test it. The results are summarized in the parallel coordinate plots that show the

results of different runs by using the eight models. We found that the targets *Weight<sup>a</sup>* (Fig. 8) and *Evaporation<sup>a</sup>* (Fig. 9) can be well fitted by some models (Boosted Trees, Random Forest, MARS, and Neural Network). However, the prediction results are not always stable (sometimes the model performance dropped severely). This could be caused by the fact that the sample size is not very large. Additionally, there might be some issues with the consistency of the data that was generated in the tests. For the target *Elongation<sup>a</sup>* (Fig. 10), all models suffered when predicting the value. We hypothesize that the predictors did not correlate well with the targets.




Fig. 8. RMSE and R<sup>2</sup> values for the Weight<sup>a</sup> target. The multiple colored lines represent the prediction results for a common cross-validation holdout set. Both RMSE and R<sup>2</sup> suggest that some models (like Boosted Trees and Neural Network) can fit the data very well.




Fig. 9: RMSE and R<sup>2</sup> values for the Evaporation<sup>a</sup> target. The Boosted Trees algorithm has relatively low RMSE and high R<sup>2</sup> values.




Fig. 10. RMSE and R<sup>2</sup> values for the Elongation<sup>a</sup> target. For both RMSE and R<sup>2</sup> all algorithms failed to predict the target accurately. It could be because of the problems in our measurement data.



### 5.2. Second analysis

In the second analysis, we used the targets that were created by the external testing partner. Five repeats of 10-fold cross-validation were used to tune and evaluate the various models. Through this procedure, we found that the predicted results of *Energy Index<sup>b</sup>* (Fig. 11) and *Elongation<sup>b</sup>* (Fig. 12) were quite promising by the Boosted Trees algorithm. The model was quite robust in predicting the results for both variables. For *Comfort Index<sup>b</sup>* (Fig. 13), *Unload Force<sup>b</sup>* (Fig. 14), and *Garment Diameter<sup>b</sup>* (Fig. 15) the results looked good in most runs, but sometimes the model suffered severely. The results of predicting *Power Index<sup>b</sup>* were not as good (Fig. 16).

This could be related to the fact that the dataset only contains the values 2 and 3, and the classification for these two targets based on the predictors are not easy.

### 5.3. Final Model Selection

Based on the two analyses, we finally selected six models by eliminating Robust Linear Regression and Elastic Net due to their similar poor performance with Linear Regression. The final evaluation results (shown in Table 7 and Table 8) were generated by leave-one-out cross-validation (LOOCV) which fits more training samples than 10-fold cross validation for one resampled estimate.




Fig. 11. RMSE and  $R^2$  values for the Energy Index<sup>b</sup> target. The Boosted Trees algorithm performs well, visible in the low RMSE and high  $R^2$  values.




Fig. 12. RMSE and  $R^2$  values for the Elongation<sup>b</sup> target. The Boosted Trees algorithm performs well, visible in the low RMSE and high  $R^2$  values.




Fig. 13. RMSE and  $R^2$  values for the Comfort Index<sup>b</sup> target. Some problems with models (especially the linear algorithms).

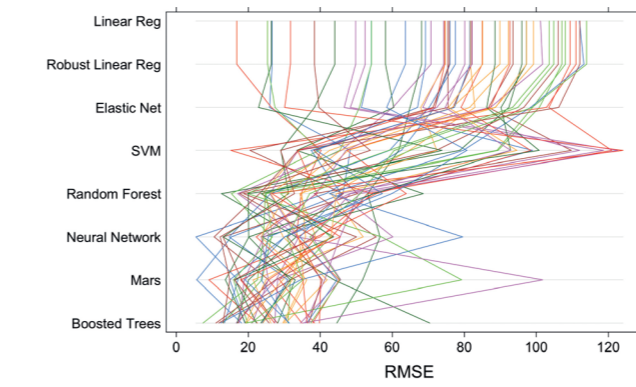



Fig. 14. RMSE and  $R^2$  values for the Unload Force<sup>b</sup> target.

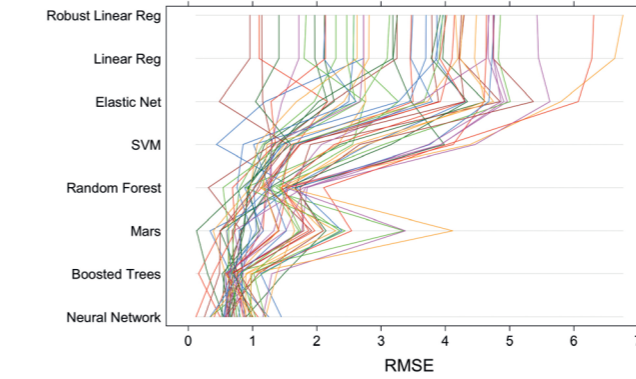


Fig. 15. RMSE and  $R^2$  values for the Garment Diameter<sup>b</sup> target.

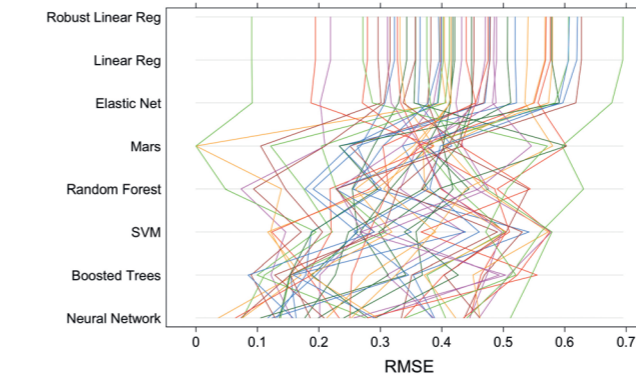



Fig. 16. RMSE and  $R^2$  values for the Power Index<sup>b</sup> target. It is clear from both the RMSE and  $R^2$  plots that all models suffered in this case.



parameters of the pattern, such as stitch type and stitch structure. The window shows a visual representation of what the knitting pattern will look like, as well as an overview of the direct feedback about the predicted functional values (such as breathability, elongation, weight, evaporation, etc.). When the user confirms the pattern it will be saved in the pattern samples library. Finally, a shape can be loaded onto the pattern canvas (Fig. 18.b). By selecting the shape then clicking on a sample in the pattern samples library, the software will show the visualization of the pattern into the shape. At the same time, the prediction results panel will update its value for the designed fabric.

The User Interface (UI) design was a process in collaboration with the knitwear designers, who would eventually use the interface. In the process we first tried to understand the requirements, then built a mock-up of the interface, and finally implemented the working learning algorithms with training data in a prototype.

### 6.1. Understanding the requirements

The design of the interface started by understanding how the predictive capabilities of this tool can play a role in the design process of functional knitwear. We asked our knitwear design partners what their current process looks like and which tools they used in each step of the process. Summarized, this process contains the following phases:

- Creating the concept based on the visual direction, gathering inspiration for patterns and graphics (for example by manipulating and combining patterns).
- Creation of a pattern library. Several patterns that can be tested for different knit combinations and through trial and error achieve the right functionality.
- Subjective assessment of the visual and functional aspects of the test results, and mapping them on them body. There is an opportunity in this step to use objective measurements.
- Combining the body mapped patterns into one full garment design.
- Creation of a square pattern file where both sides are matching (to create a tubular shape).
- Start engineering process to integrate the design onto a 3D form.

Based on this process, our initial aim was to use the tool in the step which normally requires iterative testing (Step b). The tool should offer the designer the possibility to evaluate and explore the changes in functionality, without having to physically knit each sample. This could result in faster explorations, as well as more flexibility in the exploration process. The main starting point for this process is the visual patterns which have already been designed during Step a. Therefore, the tool should be able to use the visual patterns as inputs and allow the designer to make variations of the knitting structures to determine the values of the functionalities.

### 6.2. User interface mock-up

Based on the directions set out in the requirements phase, a mockup was created using Balsamiq Wireframes software (Balsamiq, n.d.). The main interface (Fig. 17) consists of the pattern canvas, prediction results panel, and pattern samples library. The pattern canvas loads a vector visual pattern and separates the different objects in separate layers onto the canvas. The property adjustments panel gives a quick overview of the prediction results for the designed fabric. The pattern samples library panel lets users reuse patterns they have created before. Clicking on one of the patterns will load the pattern design window (Fig. 18.a). This window allows the designer to change knitting

### 6.3. Prototype development

When implementing the mockup, we realized that our current dataset did not allow for the translation of visual patterns into predicted values. In our dataset we worked with tube coverage percentage, which assumes a full area of the fabric to be covered with a specific knit type and knit structure. Therefore, we decided to only implement the change of tube coverage percentage instead of the design of specific visual patterns. The prototype was developed using Unity (Unity, n.d.), a software normally used for game development, but which also has the capability to prototype 2D interfaces. The main interface of the tool (Fig. 19) was divided into two main areas. The pattern design area shows the representation of the fabric by a rectangle consisting of two areas. A draggable line allows the designer to change the coverage percentage. The knitting type and knitting structure can be adapted by using the dropdown lists. When manipulating the pattern values, the software will calculate the predicted values of the functionalities in real time and display them in the predicted values table on the right side of the interface. The designer has the possibility of switching between different Machine Learning algorithms in order to see how this will change the predicted values of the target variables. The software will also display the reliability score in the form of colored stars, based on the RMSE and  $R^2$  values. This enables the designer to make a decision on the design based on the reliability of the intended functionalities.

During the project process we came to several important insights, which we think might be useful for others pursuing this approach. The findings are separated based on each section of the previously described parts of the process.

### 7.1. Data Model

One of the particular challenges when defining the data model was to make decisions about the predictor values and target values. This meant that it was necessary to simplify parts of the knitting parameters and even ignore other parameters. For example, we decided to only use two types of yarns: nylon and elastane. Materials can have a big influence on the resulting properties of the knitted fabric. Even the same material with a different dye might react

Algorithm	Lab test results			External test results					
	Weight	Elongation	Evaporation	Power index	Comfort index	Energy index	Unload Force	Elongation	Garment diameter
Linear Regression	7.610	0.045	2.342	0.419	1.225	1.692	61.907	12.531	2.786
MARS	5.570	0.046	1.414	0.228	0.365	0.411	28.898	4.669	1.093
Neural Network	3.301	0.039	0.520	0.332	0.423	0.427	38.341	4.763	0.622
SVM	6.873	0.038	1.045	0.342	0.634	1.037	46.321	10.134	1.226
Random Forest	5.817	0.046	1.435	0.359	0.748	1.110	40.381	9.360	1.362
Boosted Trees	3.724	0.043	0.775	0.364	0.431	0.512	29.898	4.228	0.886

Table 7. The RMSE of the six selected algorithms in the final evaluation.

Algorithm	Lab test results			External test results					
	Weight	Elongation	Evaporation	Power index	Comfort index	Energy index	Unload Force	Elongation	Garment diameter
Linear Regression	0.890	0.067	0.524	0.214	0.377	0.643	0.846	0.883	0.712
MARS	0.941	0.053	0.825	0.755	0.943	0.979	0.966	0.984	0.957
Neural Network	0.980	0.325	0.977	0.492	0.924	0.977	0.941	0.985	0.986
SVM	0.922	0.300	0.913	0.465	0.829	0.869	0.922	0.933	0.954
Random Forest	0.936	0.001	0.831	0.400	0.856	0.865	0.936	0.950	0.931
Boosted Trees	0.975	0.133	0.948	0.385	0.921	0.970	0.965	0.987	0.971

Table 8. The  $R^2$  of the six selected algorithms in the final evaluation. This table suggests that the lab-tested elongation value is probably not that accurate as the external tested elongation value.



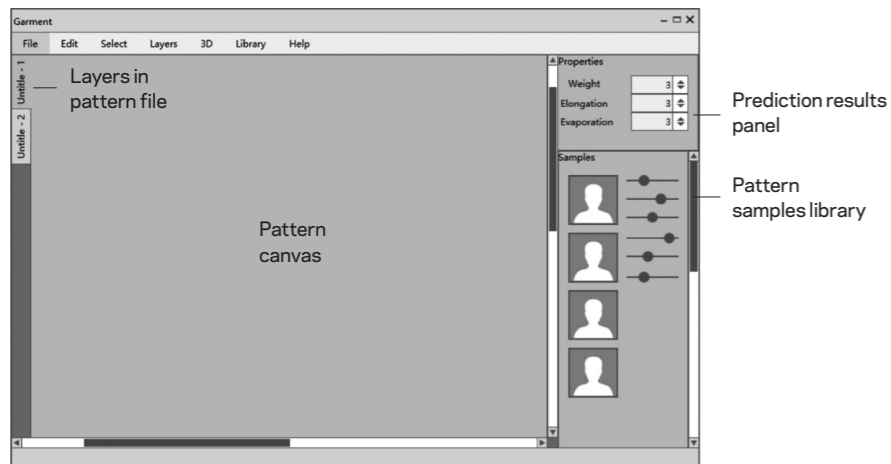


Fig. 17. The proposed main window of the software.

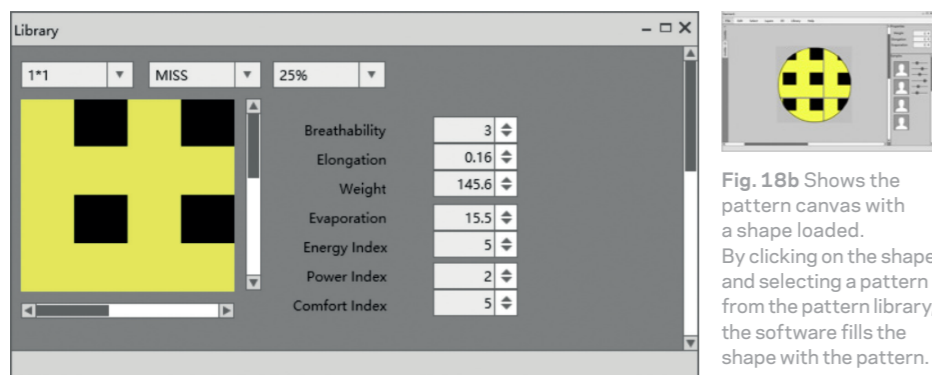


Fig. 18b Shows the pattern canvas with a shape loaded. By clicking on the shape and selecting a pattern from the pattern library, the software fills the shape with the pattern.

Fig. 18a Shows the pattern design window. By changing the values of the knitting pattern (such as knitting structure and knitting type), the visual representation of the pattern changes. The values on the right show the predicted values of the functionalities.

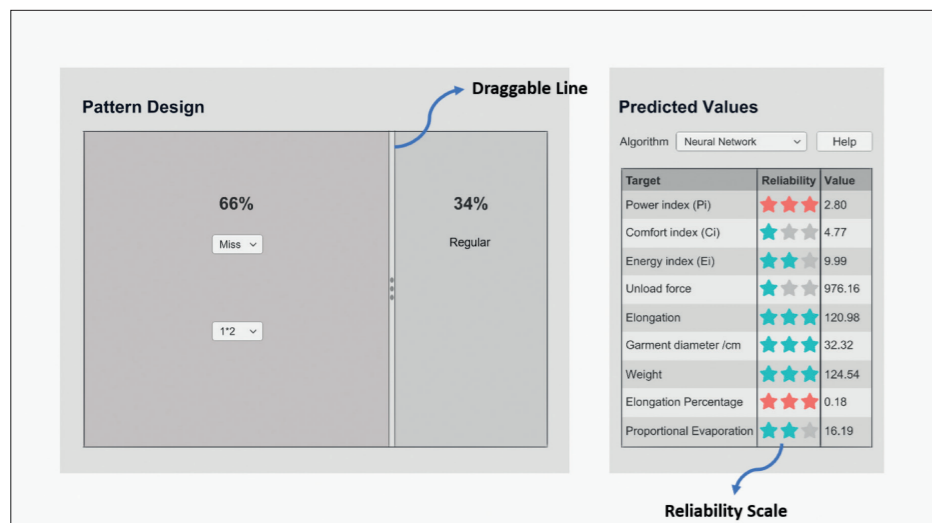


Fig. 19. Screenshot of the working prototype. The control area in the left side allows the designer to change the proportion of special knit type and structure by dragging the line left and right. During the manipulation the values on the right will give direct feedback about the predicted feedback. By changing the algorithm in the drop-down list different predictions can be tested. The statistics give feedback about the reliability of the prediction.

differently. Using different materials also complicates the fabrication process, as machine settings need to be tweaked for the particular yarn. We decided to try to eliminate most of these variabilities by keeping the material constant. We used tube coverage percentage to indicate different patterns, instead of graphics representing the visual knitting patterns. Normally, knitwear is designed by creating visual patterns (Fig. 3). We simplified this for two main reasons. 1) A uniform visual language for knitting patterns was missing. When exporting the various knitting pattern data files, we found that, in different types of circular knitting machines and programs, the same color could have similar meaning and patterns could have different sizes. 2) The visual designs normally created by knitwear designers are highly-complex and contain too many variables. We did not have the resources to create a large enough dataset that could be used to train the algorithms based on these variabilities.

#### 7.2. Data Collection and Preparation

The main challenge of the data collection and preparation stage was to acquire testing data necessary for the learning algorithms. While we had multiple tests planned, we were only able to execute basic testing in our internal Lab. We relied on an external Lab for testing additional functionalities. One of the disadvantages of this approach was that the test methods were proprietary and we did not have insight into the procedure and quality. One of the problems we faced was caused by the need to do testing of tubular structures. When a fabric has a tubular shape there is, by its nature, no end or beginning. Hence, it becomes harder to devise test methods which are supposed to measure the specific functionality of the whole fabric. For example, when we tested evaporation, did we mean the evaporation of the fabric as a whole or just the area with the specific knit type and knit structure applied? Eventually we decided to use a hybrid approach. For *Evaporation<sup>a</sup>* we measured the proportion of the knit structures compared to the plain knit structure. For *Elongation<sup>a</sup>* we measured the elongation of the whole fabric tube.

#### 7.3. Machine learning model building, evaluation and selection

We compared several machine learning algorithms to find out their capability to predict the target variables. There were some target variables with high reliability rates (such as *Weight<sup>a</sup>*, *Evaporation<sup>a</sup>*, *Energy Index<sup>b</sup>*, and *Elongation<sup>b</sup>*). However, target variables such as *Elongation<sup>a</sup>* and *Power Index<sup>b</sup>* had severe problems. We think that one cause of this variability is due to the limitation in sample size. Because we only had a set of 36 samples, we needed to rely on techniques such as cross-validation to train the models. Any inconsistency in the dataset could be amplified and result in less reliable predictions. One of the other insights when testing the models was that different algorithms will have different predictive capabilities. As a result, different target variables can have more suitable algorithms for predicting them. Rather than finding the perfect algorithm for all variables, we think it can benefit the designer to be able to have insight into these reliability scores so that they can become part of the tools used in the design process.

#### 7.4. Designing the User Interface

The initial mockup that we developed functioned as a tool to help communication within the team working on the project. For example, we discovered that the current predictors (knitting stitch, knitting type, and coverage) are quite technical and normally not directly considered by the knitwear designer. It would be the knitting technician who takes the visual design and realizes the translation to technical knitting parameters. Therefore, with a tool like this, at which level the designer should be able to manipulate the design remains a question.

One of the other challenges was to find a balance between how many of the Machine Learning features should be open for manipulation in the User Interface. In the first mockup, most of the control parameters were hidden and the algorithms would only show the *target variables* and predictor variables. During the process, as we discovered that different algorithms will have some variety in their output, we realized that it could be valuable for the designer to show the different algorithms, which could also give more creative control to the designers to be able to explore the different prediction results.

Functionalities (target variables) are currently the prediction output of the machine learning algorithm. We have also considered whether it could be possible to reverse the process and be able to use the functionalities as inputs to generate the target variables. This type of a more generative approach is something to explore in future work.

## 8 CONCLUSION

The main research question that was explored in this article was “How can designers benefit from intelligent design software for the manufacturing of personalized advanced functionalities in textile products?”. This question was approached from three sub questions:

1. *What kind of advanced functionalities can be considered for the personalization process of knitwear?*

The process to decide which functionalities to use in the prediction is discussed in Section 3.2, and the final functionalities chosen are shown in Table 2. We expected that the use case (seamless knitted running tights) would be an important guide to help us decide the functionalities and basic properties of the fabric. It was helpful indeed as it helped us to constrain the predictor variables and target variables and at the same time make decisions about the materials (for example, to only use nylon and elastane). However, when the project progressed further, the constraints of testing capabilities, sampling resources, and technical feasibility became equally important driving forces. In this case we discovered that it is better to start with a model which has limited predictor and target variables. Once the process is in place, and it is better understood how the variables connect to each other, it is possible to further extend the

functionalities to have a better match with the use case.

## 2. How to design interactions and interfaces that use intelligent predictive algorithms to stimulate creativity during the fashion design process?

One of the crucial decisions was to decide how the software could represent the knitting pattern in the software. From the designer’s perspective, directly interacting with the technical knitting patterns wouldn’t be needed. Instead, it would be preferable to use a more abstract visual representation that focuses on visual and functional qualities. However, for the algorithm to work accurately, it is necessary to work with pattern representation and predictor variables which come as close as possible to the final manufactured fabric. Based on our current exploration, we think there is an interesting tension here where future research can help to find new opportunities. One of our concerns is related to the process of replacing physical sampling with virtual sampling. By eliminating cycles of iterative physical manufacturing (one of the goals of developing this software), the designer might lose the chance to gain inspiration from manufacturing “accidents.” On the other hand, new control possibilities and insight for the designer about the algorithms (such as trying different algorithms and models) can also be a new source of creativity, leading to results which wouldn’t have been possible with a traditional physical approach.

## 3. How will predictive software impact the manufacturing process for other stakeholders and production steps?

One of the starting points of this exploration was the knitting development process (Fig. 1), which normally is a process that involves many sequential steps by different people involved (fashion designer, knitwear designer, knitting engineer, and machine technician). It wasn’t our purpose to necessarily change this process as we recognize that diverse expertise is required, especially in advanced manufacturing. However, it became clear that the software did start to bridge the gap between the designer and the knitting engineer, perhaps more than is usually the case. This happened because we needed the algorithm to work with certain predictor variables (stitch type, stich structure), which the knitwear designer normally wouldn’t be able to control. Knitwear designers usually create their own pattern files, based on colors and functionalities meaningful for the final end-product, and knitting engineers and machine technicians use a translated pattern file, where colors have a different purpose to represent meaningful instructions for the machine. Inevitably, these changes in capabilities of the different stakeholders could lead to changes in work procedures and dynamics. We think that for future work it is necessary to evaluate implications by evaluating the software with other stakeholders in the knitwear manufac-

turing process. We presented the process in this case-study as linear steps. However, the actual process has been an iterative exploration. Since this project included tasks between different disciplines within the team (knitwear design, computer science, and industrial design), we had to move in small steps as it was never really clear how each step would unfold in the beginning. Therefore, we hope that this case study can help others to anticipate the challenges of such multi-disciplinary projects.

Finally, it is also necessary to note that much of the research and development work in the field of seamless knit technology is proprietary and happens behind closed doors. We hope that this study can contribute to more openness and accessibility of knowledge within this area. We also acknowledge that the test processes and results of the project are not yet fully resolved. However, this research is important because it highlights the complexity of the task and provides an initial set of processes to measure textile behavior and performance, and a way to use this data to inform a predictive model.

### ACKNOWLEDGEMENTS

This work was supported by the National Natural Science Foundation of China (NSFC, Grant No. 51750110497) and by Xi’an Jiaotong-Liverpool University (Grant No. RDF-13-02-19 and RDF-17-01-54). We would also like to thank Santoni Shanghai for their generosity in providing the resources and support to make this project possible.

### BIOGRAPHIES

#### Martijn ten Bhömer

Xi’an Jiaotong-Liverpool University

Dr. Martijn ten Bhömer is a lecturer with the Industrial Design Department, program director of the Master of Industrial Design program, and director of the Digital Manufacturing Lab at Xi’an Jiaotong-Liverpool University. He did his PhD studies in the research group “Designing Quality in Interaction” with the Industrial Design Department at Eindhoven University of Technology. Before joining the Industrial Design Department, Martijn accumulated hands-on experience in industry by working at companies such as Microsoft Research in UK, Deutsche Telekom in Germany, OMsignal in Canada, and Bambi Medical in the Netherlands. In his research he investigates how an embodied approach to technology can underpin the design and manufacturing of smart textile products and services.

#### Hai-Ning Liang

Xi’an Jiaotong-Liverpool University

Dr. Hai-Ning Liang is an Associate Professor with the Department of Computer Science and Software Engineering at Xi’an Jiaotong-Liverpool University (XJTLLU). He is the deputy director of the Suzhou Key Lab for Virtual Reality Technologies. He earned his PhD in Computer Science from the University of Western Ontario. His research combines HCI and Information Visualization to develop innovative computer interfaces for wearable, augmented/virtual reality, and mobile devices.

#### Difeng Yu

Xi’an Jiaotong-Liverpool University

Difeng Yu received his BSc degree with honors in Computer Science from Xi’an Jiaotong-Liverpool University (XJTLLU) in 2018. He is currently a research assistant at VR Lab at XJTLLU. His research interests center around the field of human-computer interaction (HCI). He is also interested in machine learning technologies.

#### Yuanjin Liu

Xi’an Jiaotong-Liverpool University

Yuanjin Liu received his BEng degree with honors in Electrical Engineering and Automation from Xi’an Jiaotong-Liverpool University (XJTLLU) in 2017 and his MDes degree with honors in Industrial Design from the University of Liverpool in 2019. His Master’s thesis focused on using movement design to enhance the emotional response of intelligent products. He is currently working as a designer and researcher in the field of Human-Computer Interaction.

#### Yifan Zhang

Xi’an Jiaotong-Liverpool University

Yifan Zhang received his BEng degree with honors in Electronics and Electrical Engineering from Xi’an Jiaotong-Liverpool University in 2014. He received his MSc degree with honors in Automation and Control from Newcastle University in 2015 and an MDes in Industrial Design from the University of Liverpool in 2019. His thesis focused on the visual representation of human behavior in product design.

#### Eva de Laat

Carola Leegwater

Eva x Carola

Eva x Carola is a design studio created by Carola Leegwater and Eva de Laat. Both designers majored in Fashion Management and International Production at the renowned Amsterdam Fashion Institute. After graduating Eva and Carola worked with the sportswear brand Nike where they developed and engineered products for international events such as the Tour de France, the FIFA World Cup, and the Olympic Games. Today, Eva x Carola are pioneers in the sports apparel industry researching, developing, and creating cutting-edge textiles that not only deliver unique benefits in wellness and sustainability, but are also tailored to the needs of the athlete. Recently nominated for the Future Textiles Awards, the duo collaborates with companies such as Santoni Shanghai, Lenzing, and Woolmark to create innovative activewear that turns away from conventional design and offers forward-thinking and intelligent alternatives.

### REFERENCES

- Alpaydin, Ethem. 2014. Introduction to Machine Learning. Cambridge, Massachusetts ; London, England : The MIT Press, 2014
- Balsamiq, n.d. “Balsamiq Wireframes | Balsamiq.” Accessed April 7, 2019. <https://balsamiq.com/wireframes/>.
- Bishop, Christopher M. 2006. Pattern recognition and machine learning. New York: Springer.
- Black, Sandy. 2002. “Innovative Knitwear Design Utilising Seamless and Unconventional Construction.” Proceedings of the IFFTI International Conference Fashion and Textiles: The New Frontiers, 253-262.
- Born, Dennis-Peter, Billy Sperlich, and Hans-Christer Holmberg. 2013. “Bringing Light into the Dark: Effects of Compression Clothing on Performance and Recovery.” International Journal of Sports Physiology and Performance 8 (1): 4–18.
- Eckert, Claudia. 2001. “The Communication Bottleneck in Knitwear Design: Analysis and Computing Solutions.” Computer Supported Cooperative Work (CSCW) 10 (1): 29-74.
- Gorecky, Dominic, Mathias Schmitt, Matthias Loskyll, and Detlef Zuhlke. 2014. “Human-Machine-Interaction in the Industry 4.0 Era.” In Proceedings of the 2014 12th IEEE International Conference on Industrial Informatics (INDIN), 289-294.
- Hill, Jessica A., Glyn Howatson, Ken A. van Someren, Ian Walshe, and Charles R. Pedlar. 2014. “Influence of Compression Garments on Recovery After Marathon Running.” Journal of Strength and Conditioning Research 28 (8): 2228-35.
- Hsu, Chih-Hung, and Mao-Jiun J. Wang. 2005. “Using Decision Tree-Based Data Mining to Establish a Sizing System for the Manufacture of Garments.” The International Journal of Advanced Manufacturing Technology 26 (5-6): 669-74.
- INVISTA Apparel & Advanced Textiles. 2017. “Made to Measure: Lycra® Sport Performance Indexing.” Last modified January 26, 2017. <https://connect.lycra.com/en/News-and-Video/Blog/2017/01/Lycra-Sport-Performance>.
- Jaouachi, Boubaker, and Faouzi Khedher. 2015. “Evaluation of Sewed Thread Consumption of Jean Trousers Using Neural Network and Regression Methods.” Fibres & Textiles in Eastern Europe 23 (3(111)): 91-96.
- Kagermann, Henning, Wolfgang Wahlster, and Johannes Helbig. 2013. Recommendations for Implementing the Strategic Initiative INDUSTRIE 4.0 : Securing the Future of German Manufacturing Industry. Final report of the Industrie 4.0 working group. Berlin: Forschungsunion.
- Karmon, Ayelet, Yoav Sterman, Tom Shaked, Eyal Sheffer, and Shoval Nir. 2018. “KNITIT: A Computational Tool for Design, Simulation, and Fabrication of Multiple Structured Knits.” In Proceedings of the 2nd ACM Symposium on Computational Fabrication, 1-10. ACM Press.
- Kuhn, Max, and Kjell Johnson. 2013. Applied predictive modeling. Vol. 26. New York: Springer.
- Lasi, Heiner, Peter Fettke, Thomas Feld, and Michael Hoffmann. 2014. “Industry 4.0.” Business & Information Systems Engineering 6 (4): 239–42.
- Lau, F., and Winnie Yu. 2016. “Seamless Knitting of Intimate Apparel.” In Advances in Women’s Intimate Apparel Technology, 55-68. Cambridge: Woodhead Publishing.
- Li, Min, Dong-Ping Li, Wei-Yuan Zhang, and Xiao-Zhong Tang. 2009. “A multiple regression model for predicting comfort sensation of knitted fabric in sports condition based on objective properties.” In 2009 Second International Conference on Information and Computing Science 3:372-375. IEEE.
- Liu, Su, Chenxiao Yang, Yuanfang Zhao, Xiao Ming Tao, Jiahui Tong, and Li Li. 2016. “The Impact of Float Stitches on the Resistance of Conductive Knitted Structures.” Textile Research Journal 86 (14): 1455-73.
- Matković, Vesna. 2010. “The Power of Fashion: The Influence of Knitting Design on the Development of Knitting Technology.” Textile: The Journal of Cloth and Culture 8 (2): 122-47.
- Matusiak, Małgorzata. 2015. “Application of Artificial Neural Networks to Predict the Air Permeability of Woven Fabrics.” Fibres & Textiles in Eastern Europe 23 (1):41-48.
- McCann, James, Lea Albaugh, Vidya Narayanan, April Grow, Wojciech Matusik, Jennifer Mankoff, and Jessica Hodgins. 2016. “A Compiler for 3D Machine Knitting.” ACM Transactions on Graphics (TOG) 35 (4): 49.

- Ogulata, S.N., C Sahin, RT Ogulata, and Onur Balci. 2006. “The Prediction of Elongation and Recovery of Woven Bi-Stretch Fabric Using Artificial Neural Network and Linear Regression Models.” Fibres & Textiles in Eastern Europe 14 (2):46-49.
- Power, Jess. 2018. “Advanced Knitting Technologies for High-Performance Apparel.” In High-Performance Apparel, 113-27. Cambridge: Woodhead Publishing.
- Sayer, Kate, Jacquie Wilson, and Simon Challis. 2006. “Seamless Knitwear - the Design Skills Gap.” The Design Journal 9 (2): 39-51.
- Shima Seiki. n.d. “SDS-ONE APEX3 | Design Systems | Products | SHIMA SEIKI.” Accessed April 7, 2019. [http://www.shimaseiki.com/product/design/sdsone\\_apex/](http://www.shimaseiki.com/product/design/sdsone_apex/).
- Slocum, Donald B., and Stanley L James. 1968. “Biomechanics of Running.” JAMA 205 (11): 721-28.
- Spencer, David J. 2001. Knitting Technology: a Comprehensive Handbook and Practical Guide. 3rd edition. Cambridge: Woodhead Publishing.
- ten Bhömer, Martijn, Ruggero Canova, and Eva de Laat. 2018. “Body Inspired Design for Knitted Body-Protection Wearables.” In Proceedings of the 2018 ACM Conference Companion Publication on Designing Interactive Systems, 135-39. ACM Press.
- ten Bhömer, Martijn, Eunjeong Jeon, and Kristi Kuusk. 2013. “Vibe-Ing: Designing a Smart Textile Care Tool for the Treatment of Osteoporosis.” In Proceedings of the 8th International Conference on Design and Semantics of Form and Movement, 192-195. Koningklijke Philips Design.
- Unity. n.d. “Unity.” Accessed April 7, 2019. <https://unity3d.com/>.
- Vasconcelos, Fernando Barros de, Fabiano Casaca, Fernanda Gomes De Vasconcelos, João Paulo Pereira Marcicano, and Regina Aparecida Sanches. 2013. “Design of Elastic Garments for Sports in Circular Knitting.” International Journal of Textile and Fashion Technology 3 (1): 39–48.
- Yildirim, Pelin, Derya Birant, and Tuba Alpyildiz. 2018. “Data Mining and Machine Learning in Textile Industry.” Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery 8 (1): e1228.

M. ten Bhömer, H-N. Liang, D. Yu, Y. Liu,  
Y. Zhang, E. de Laat i C. Leegwater

*Disseny d'eines predictives per obtenir  
funcions personalitzades en peces de roba  
esportiva de punt*

Traducció al Català

PARAULES CLAU

Gèneres de Punt, Disseny d'Interacció, Indústria 4.0, Aprenentatge Automàtic, Intel·ligència Artificial, Disseny d'Interfície, Punt Circular.

RESUM

Els progressos en tècniques de fabricació tèxtil avançada –com les màquines de teixir 3D que produeixen teixit ajustat al cos– permeten crear peces de roba pràcticament acabades, que necessiten pocs passos més de producció (o cap) abans d'estar totalment enllestides. A més, la tecnologia de teixidura avançada combinada amb l'ús de nous materials permet integrar noves funcions a les peces de roba “punt a punt”. Encara queda camp per avançar en la millora de les eines de disseny per a la fabricació avançada de teixits amb tecnologies com ara la recollida de dades, l'aprenentatge automàtic o la simulació. Aquest plantejament reflecteix el potencial de la indústria 4.0, en què convergeixen cada cop més el disseny, el desenvolupament de producte i la fabricació. Tanmateix, actualment se sap ben poca cosa sobre l'impacte que aquestes noves tecnologies i eines poden tenir en el procés





àrees estructurals, que tenen un paper important a l'hora de definir les funcions. Per exemple, una samarreta esportiva pot tenir més compressió al voltant dels tríceps per facilitar la recuperació de la musculatura i alhora pot presentar una estructura oberta a les axelles per controlar la temperatura durant l'exercici. Per reduir la complexitat, vam decidir que a cada tela només combinarien un tipus de punt amb el punt llis. D'altra banda, en lloc de crear teles de diverses formes vam decidir treballar només en un àrea rectangular d'un tipus concret de punt i d'estructura. Vam simplificar encara més aquestes variabilitats estructurals triant quatre dissenys diferents d'estructura de la tela: 25%, 50%, 75% i 100% (tal com es veu a la Fig. 6). Per exemple, una cobertura del 25% de l'estructura amb 1 x 1 basta significa que el 25% de la superfície del teixit en forma de tub està coberta amb 1 x 1 basta, i l'altre 75%, amb punt llis.

#### 3.2. Variables objectiu

Les peces compressives, aquelles que es poden crear amb elasta i niló, són molt utilitzades per atletes i gimnastes. El propòsit principal d'aquestes peces és oferir als atletes una millor recuperació i aconseguir que assoleixin un rendiment més alt (Hill et al. 2014). Tot i que la investigació encara no és concloent, suggereix que les peces compressives poden millorar la sensibilitat de les articulacions, el flux sanguini local, l'eliminació de residus, la gestió de carrera, i reduir la sudoració, les oscil·lacions musculars i el dolor muscular posterior a l'exercici (Born, Sperlich i Holmberg 2013). Així doncs, la roba que duen els atletes hauria de presentar un bon rendiment en funcions com la compressió, el confort, la recuperació, l'absorció capil·lar, la transpiració, la permeabilitat a l'aire, etcètera. Per tant, les variables objectiu que el dissenyador d'aquests tipus de roba hauria d'analitzar estan relacionades amb les funcions que ofereixen les peces compressives. Vam tenir en compte diverses funcions durant el procés:

- Absorció capil·lar (calculada utilitzant el test d'absorció, que consisteix a amidar la distància que pot avançar l'aigua per una peça de roba que penja).
- Grau de fregament (calculat utilitzant el coeficient de fricció, un pla inclinat per mesurar la força que necessita un pes per rrelliscar per sobre de la tela).
- Absorció (calculant la velocitat d'absorció de l'aigua).
- Permeabilitat (mesurada amb el mètode de la copa cap amunt: s'utilitza la tela com a membrana per veure quina quantitat d'aigua entra a la copa).
- Aïllament (es podria mesurar amb una placa elèctrica o amb un maniquí tèrmic).
- Compressió (mesurant l'elongació provocada en la tela per un pes determinat).
- Sensació de confort (mesurada amb qüestionaris homologats i escales de valoració de reaccions a la tela).

Vam acabar creant una llista resum de variables objectiu (Taula 2). L'elecció de les variables objectiu mostra un equilibri entre les capacitats de mesurament i les instal·lacions del laboratori d'una banda i la decisió de determinar la prioritat de les funcions més importants, de l'altra.

Paràmetres bàsics

Els paràmetres bàsics poden ajudar els dissenyadors a avaluar les propietats bàsiques de la tela dissenyada per a una peça. Atès que cada tela tindrà propietats diferents a causa de les diferències en el tipus de punt, l'estructura i la cobertura, per norma general el dissenyador no coneix exactament les propietats del producte fabricat final. El pes i el diàmetre de la tela de tub són dues variables principals que vam triar com a objectiu.

Paràmetres dinàmics

Les peces compressives poden reduir els símptomes associats a lesions musculars gràcies a l'ajuda mecànica al teixit danyat i a una reducció en el moviment del membre. La variable de la força de descàrrega indicarà l'energia que la peça transmet al cos. Que la pressió constant sobre el cos humà es mantingui depèn de l'elasticitat de la peça compressiva, que es pot mesurar amb la variable objectiu de l'elongació. La transferència d'humitat de la tela també pot influir en el confort fisiològic. Si la transpiració supera la capacitat d'absorció, l'usuari pot sentir incomoditat. Per això es va triar l'evaporació com a variable objectiu per valorar aquesta funció.

## TEMES DE DISSENY #35

Índex de rendiment

Per comparar les nostres variables objectiu vam utilitzar una tercera categoria de variables objectiu que ens va proporcionar un auditor homologat. L'índex de rendiment és una eina de la cadena de subministrament que pot afavorir la comunicació entre els diferents actors, ja que promet una escala quantitativa objectiva per a diversos paràmetres de la tela (INVISTA Apparel & Advanced Textiles 2017). L'índex de rendiment s'obté a partir de tres valors: l'índex de potència, l'índex d'energia i l'índex de confort. L'índex de potència mesura el factor de rendiment de la tela en una escala d'u a deu. L'índex de confort mesura la capacitat que té d'actuar com a «segona pell» i permetre llibertat de moviment. L'índex d'energia indica l'energia que la peça absorbeix en moviment.

4
<p>RECOLLIDA I PREPARACIÓ DE DADES</p>

Per entrenar els algoritmes d'aprenentatge automàtic, va caler crear una sèrie de dades perquè els algoritmes hi basessin les seves prediccions. La creació d'aquestes dades d'entrenament va constar de dues parts. En primer lloc va ser necessari crear mostres físiques de tela amb diferents combinacions de variables predictores. En segon lloc va caldre elaborar un conjunt de protocols de prova per avaluar el rendiment de les variables objectiu amb les mostres esmentades.

#### 4.1. Fabricació de les mostres de tela

Vam utilitzar màquines de teixir circulars amb les quals vam fabricar 36 teles d'estructura tubular (la Fig. 7 en mostra una) que cobreixen totes les variacions predictores possibles (la Taula 3 mostra totes les combinacions, mentre que la Taula 4 mostra les mostres físiques ordenades per variació).

#### 4.2. Proves de les mostres de tela

Abans de fer les proves d'elongació i evaporació, es va mesurar el pesa de cada mostra. Els mesuraments de les diferents mostres es van fer amb una balança electrònica. L'elongacióa es va mesurar exercint una força de tracció d'un quilogram sobre les mostres tubulars. L'elongació es va amidar amb un regle, i la magnitud de la variació es va calcular dividint la longitud inicial entre la longitud en exercir la força. L'evaporacióa es va mesurar escampant un mil·lilitre d'aigua destil·lada a la zona analitzada de la peça i enregistrant el temps que tarda a evaporar-se. Durant aquesta prova es va veure clarament que és difícil generalitzar el mesurament d'una funció localitzada (evaporació) a tota la tela tubular. Per exemple, a l'hora de mesurar l'evaporació d'una tela de malla carregada 1 x 2 (50% de cobertura), el valor de l'evaporació podia variar enormement entre la part de punt llis i la part de malla carregada 1 x 2. Per això vam decidir calcular l'evaporació com una ponderació dels valors de les diferents parts. Per exemple, en el cas anterior de la tela tubular de malla carregada 1 x 2 (50% de cobertura), el valor d'evaporació va ser de 12 minuts a la zona de punt llis i de 8 minuts a la zona de malla carregada 1 x 2. Així doncs, el valor ponderat va ser de 10 minuts (12 \* 0,5 + 8 \* 0,5). El mesurament de les variables objectiu d'elongaciób, diàmetre de peçab, força de descàrregab, i de les tres variables de l'índex de rendiment (índex de potènciab, índex d'energiab i índex de confortb) es va dur a terme en un laboratori extern amb mètodes de mesurament homologats. La Taula 5 mostra els resultats de les proves.

5
<p>APRENENTATGE AUTOMÀTIC: ELABORACIÓ DEL MODEL, AVALUACIÓ I SELECCIÓ</p>

Per configurar la relació entre les variables predictores i les variables objectiu, vam comparar vuit algoritmes, que es poden dividir en tres grups: models de regressió lineal, models de regressió no lineal i models d'arbre. Els models lineals fan una predicció utilitzant una funció lineal dels predictors. Són senzills i més fàcils d'interpretar, però poden presentar una resposta pobra davant sèries de dades complexes. Els tres models lineals

## ESTUDI DE CAS

que vam provar són: regressió lineal, regressió robusta i xarxa elàstica. Els models no lineals són més potents perquè s'adapten a més tipus de corbes que les relacions lineals, però solen ser menys interpretables i més difícils d'entrenar. Vam provar els següents models no lineals: splines de regressió adaptativa multivariant (MARS, per les seves sigles en anglès), xarxes neuronals, i màquines de vectors de suport (SVM, per les seves sigles en anglès). Els models d'arbre estan entre els més utilitzats en l'aprenentatge automàtic perquè el seu ús és fàcil i poden comprendre relacions no lineals complexes. Un punt en contra és que tendeixen a memoritzar el soroll que hi ha en una sèrie de dades. Els algoritmes d'arbre que vam provar són: boscos aleatoris (random forests) i arbres potenciadors (boosted trees). Seguint la tesi de Kuhn et al. (2013) vam aplicar diferents tècniques de preprocessament als algoritmes que acabem d'indicar, tal com es mostra a la Taula 6.

Dos mètodes per mesurar l'eficàcia dels algoritmes són el d'error quadràtic mitjà (Root-Mean-Square Error, RMSE) i el del coeficient de determinació (R2). RMSE és l'error quadràtic mitjà de les diferències entre els valors que prediu un model i els valors realment observats. S'utilitza habitualment per mesurar el grau d'exactitud, per comparar errors de predicció de diferents models en una variable objectiu concreta. R2 és un altre paràmetre que vam utilitzar per avaluar els algoritmes, ja que es pot interpretar com la proporció de la informació continguda en les dades que el model pot comprendre. En ser una correlació, R2 té l'avantatge que no es regeix per cap escala. És a dir, independentment que l'escala del resultat sigui gran o petita, el valor d'R2 estarà entre 0 i 1. Per norma general, un RMSE baix i un R2 alt indiquen que el model és adequat per a la variable objecte.

Vam preparar els vuit models que acabem de presentar i els vam avaluar en dues anàlisis. La primera anàlisi es va fer amb les dades obtingudes amb les proves realitzades al nostre laboratori (pesa, elongacióa i evaporacióa) i la segona, amb les dades obtingudes a les proves del laboratori extern (índex de potènciab, índex de confortb, índex d'energiab, força de descàrregab, elongaciób i diàmetre de peçab). Després de l'avaluació, vam seleccionar els models definitius.

#### 5.1. Primera anàlisi

En aquesta primera prova, vam ajustar els models i vam comprovar-ne el rendiment en cinc repeticions de validació creuada de 10 iteracions (Kuhn et al. 2013). La validació creuada és una tècnica que s'utilitza per calcular el rendiment d'un model. Consisteix a dividir la mostra original en dades d'entrenament i dades de validació (anomenades també dades de prova). Els resultats s'expressen en forma de línies en coordenades paral·leles que mostren els resultats que donen els vuit models per a diferents seqüències. Vam veure que certs models (arbres potenciats, bosc aleatori, MARS i les xarxes neuronals) s'adapten millor als objectius de pesa (Fig. 8) i evaporacióa (Fig. 9). Tanmateix, les prediccions no sempre són estables (de vegades el rendiment del model patia una brusca caiguda). Això podria ser degut al fet que la mida de la mostra no era gaire gran. A més, les dades que es van generar a les proves podrien tenir problemes de consistència. En l'objectiu d'elongacióa (Fig. 10) tots els models van tenir problemes per predir el valor. La nostra hipòtesi és que els predictors no es correlacionaven bé amb els objectius.

#### 5.2. Segona anàlisi

En la segona anàlisi, vam utilitzar els objectius que es van crear al laboratori extern. Es van utilitzar repeticions de validació creuada de 10 iteracions per ajustar i avaluar els diferents models. Seguint aquest procediment, vam veure que la predicció que feia l'algoritme d'arbres potenciats donava resultats prometedors en els valors de l'índex d'energiab (Fig. 11) i d'elongaciób (Fig. 12). El model es va mostrar robust en la predicció de resultats per a totes dues variables. A l'índex de confortb (Fig. 13), la força de descàrregab (Fig. 14) i el diàmetre de peçab (Fig. 12) els resultats mostraven un bon comportament en la majoria de les seqüències, però de vegades el model tenia moltes dificultats per aconseguir el seu objectiu. Els resultats de la predicció de l'índex de potènciab no van ser tan bons (Fig. 16). Això podria ser degut al fet que la sèrie de dades només conté els valors 2 i 3, i no és fàcil classificar aquests dos objectius a partir dels predictors.

#### 5.3. Selecció final de model

Basant-nos en aquestes dues anàlisis, vam seleccionar sis models després d'eliminar la regressió robusta i la xarxa elàstica, ja que les dues tenien un baix rendiment amb la regressió lineal. Els resultats finals de

## M. TEN BHÖMER ET AL.

l'avaluació (que mostren la Taula 7 i la Taula 8) es van obtenir per mitjà de validació creuada amb un (Leave-One-Out Cross-Validation, LOOCV), que encaixa millor amb les mostres d'entrenament que la validació creuada amb 10 iteracions per a un càlcul amb remostreig.

6
<p>DISSENY DE LA INTERFÍCIE D'USUARI</p>

El procés de disseny de la interfície d'usuari es va fer en col·laboració amb els dissenyadors de teixits, que van acabar utilitzant la interfície. En el procés primer vam intentar comprendre els requisits, després vam construir una maqueta de la interfície i per acabar, vam crear els algoritmes d'aprenentatge que funcionen amb dades d'entrenament i vam generar un prototip.

#### 6.1. Comprendre els requisits

Abans de començar amb el disseny de la interfície calia comprendre el paper que les habilitats predictives d'aquesta eina poden tenir en el procés de disseny dels gèneres de punt. Vam preguntar als nostres socis dissenyadors de teixits com era el seu procés en aquell moment i quines eines utilitzaven en cada un dels seus passos. En resum, el procés inclou les fases següents:

- Creació del concepte a partir de la línia visual, inspirant-se en trames i gràfics (per exemple, manipulant i combinant trames).
- Creació d'una biblioteca de trames. Diverses trames que es poden provar amb diferents combinacions de punts i que amb el mètode de tanteig i error poden obtenir la funció correcta.
- Valoració subjectiva dels aspectes visual i funcional dels resultats de les proves, i mapatge d'aquests sobre el cos. En aquest pas es poden utilitzar mesuraments objectius.
- Combinació de les trames mapades sobre el cos en un disseny complet de peça.
- Creació d'un fitxer de quadrícula en què les dues cares coincideixin (per crear una forma tubular).
- Inici del procés d'enginyeria per convertir el disseny en una forma en 3D. Basant-nos en aquest procés, el nostre propòsit inicial era utilitzar l'eina corresponent al pas que normalment necessita proves iteratives (pas b). L'eina hauria d'oferir al dissenyador la possibilitat d'avaluar i analitzar els canvis en la funcionalitat, sense haver de teixir físicament cada mostra. Això aportaria més velocitat a les anàlisis i més flexibilitat al procés exploratori. El principal punt de partida d'aquest procés són les trames visuals que ja s'havien dissenyat en el pas a. Així doncs, l'eina hauria de ser capaç d'utilitzar les trames visuals com a material de treball i permetre que els dissenyadors fessin variacions en les estructures de punt per determinar els valors de les funcions..

#### 6.2. Maqueta de la interfície d'usuari

A partir de les línies fixades en la fase de requisits, es va crear una maqueta amb el programa Wireframes de Balsamiq (Balsamiq s.d). La interfície principal (Fig. 17) està formada pel llenç per a trames, el panell de resultats de predicció i una biblioteca de mostres de trames. El llenç de trames carrega una trama visual de vectors i separa els diferents objectes en capes diferents que se superposen en el llenç. El panell d'ajusts de propietats mostra una visió general dels resultats de la predicció per al cas de la tela dissenyada. La biblioteca de mostres de trames permet que els usuaris reutilitzin trames creades anteriorment. Fent clic en una de les trames s'obrirà la finestra del disseny de la trama (Fig. 18.a). Des d'aquesta finestra el dissenyador pot modificar els paràmetres del teixit, com ara el tipus de punt o l'estructura de punts. La finestra mostra una representació visual de com serà la trama de punt, i també un resum de la predicció dels valors de les diferents funcions (transpiració, elongació, pes, evaporació, etc.). Quan l'usuari confirma la trama, aquesta queda enregistrada a la biblioteca de mostres de trames. Per acabar, es pot carregar una forma al llenç (Fig. 18.b). En seleccionar la forma i fer clic en una mostra de la biblioteca de mostres de trames, el programa mostrarà la visualització de la trama en el llenç.
Ahora, el panell de resultats de prediccions actualitzarà els valors per a la tela dissenyada.

#### 6.3. Creació del prototip

En crear la maqueta vam veure que la sèrie de dades que teníem no permetia traduir les trames visuals en valors de predicció. A la nostra

## 65



sèrie de dades treballàvem amb percentatges de cobertura del tub, que pressuposa que tota una zona de la tela està coberta amb un tipus de punt concret i una estructura de punts determinada. Així doncs, vam decidir aplicar només els canvis en el percentatge de cobertura del tub en lloc d'implementar el disseny de trames visuals determinades. El prototipus es va crear amb Unity (Unity s.d.), un programa informàtic que se sol utilitzar per programar jocs, però que també pot crear prototips d'interfícies en 2D. La interfície principal de l'eina (Fig. 19) es va dividir en dues àrees principals. La zona de disseny de la trama mostra la representació d'una tela amb un rectangle amb dues parts. El dissenyador pot desplaçar una línia per modificar el percentatge de cobertura. Amb les llistes desplegablees es poden adaptar el tipus de punt i l'estructura de punts. Quan es manipulin els valors de la trama, el programa calcularà en temps real la predicció dels valors de les funcions i els presentarà a la taula de valors de predicció de la part dreta de la interfície. El dissenyador pot alternar entre els diferents algoritmes d'aprenentatge automàtic per veure com canviaria la predicció dels valors de les variables objecte. El programa també mostra el grau de fiabilitat en forma d'estrelles de colors, basant-se en els valors RMSE i R². D'aquesta manera el dissenyador pot decidir el disseny segons la fiabilitat de les funcions previstes.

7
TROBALLES

Durant el projecte vam aprendre moltes coses importants que creiem que poden ser útils per a altres persones que segueixin aquest enfocament. La classificació de les troballes es correspon amb la classificació dels diferents punts de les parts del procés que s'han descrit anteriorment.

#### 7.1. El model de dades

Un dels principals desafiaments que plantejava la definició del model de dades era decidir els valors dels predictors i dels objectius. Això volia dir que calia simplificar parts dels paràmetres del teixit i fins i tot ignorar-ne alguns. Per exemple, vam decidir utilitzar només dos tipus de fil: niló i elastà. Els materials poden influir enormement en les propietats finals de la tela. Fins i tot un mateix material amb diferents tints pot reaccionar de formes diferents. Utilitzar diferents materials també complica el procés de fabricació, perquè s'ha de corregir la configuració de la màquina per a cada fil. Vam decidir eliminar la majoria d'aquestes variabilitats i mantenir el material constant. Vam utilitzar el percentatge de cobertura del tub per indicar diferents trames, en lloc d'utilitzar gràfics que representin trames visuals de punts. Normalment les peces de punt es dissenyen creant trames visuals (Fig. 3). Vam simplificar aquest punt per dos motius. 1) No existia un llenguatge visual uniforme de trames de punts. En exportar els diferents fitxers de dades de trames de punts vam veure que, en diferents tipus de programes i màquines de teixir circulars, un mateix color podia tenir significats similars i les trames podien presentar mides diferents. 2) Els dissenys visuals que solen crear els dissenyadors de peces de punt són altament complexos i contenen massa variables. No teníem els recursos necessaris per crear una sèrie de dades prou gran per entrenar els algoritmes a partir d'aquestes variabilitats.

#### 7.2. Recollida i preparació de dades

El principal desafiament que plantejava la recollida i preparació de dades era obtenir les dades de prova necessàries per als algoritmes d'aprenentatge. Tot i que havíem plantejat multitud de proves, al nostre laboratori intern només en vam poder fer de bàsiques. Vam haver de recórrer a un laboratori extern per a les proves de funcions afegides. Un dels desavantatges d'aquest plantejament és que els mètodes de prova no eren nostres i no en coneixíem ni el procediment ni la qualitat. Va sorgir un problema quan vam haver de fer proves a estructures tubulars. Les teles tubulars, per naturalesa, no tenen ni principi ni final. Per això és especialment complicat idear mètodes de prova que se suposa que han de mesurar la funció de tota la tela. Per exemple, quan vam fer proves d'evaporació, eren proves d'evaporació de la tela en el seu conjunt o només de la zona que tenia un tipus de punt específic i una estructura de punts determinada? Al final vam decidir recórrer a un plantejament híbrid. En el cas de l'evaporacióa vam mesurar la proporció de les estructures de punts respecte de l'estructura de punt llis. Quant a l'elongacióa, vam amidar l'estirament de tot el tub de tela.

## TEMES DE DISSENY #35

*7.3. Aprenentatge automàtic: elaboració del model, avaluació i selecció*
Vam comparar diversos algoritmes d'aprenentatge automàtic per determinar-ne la capacitat de predir les variables objectiu. Algunes variables objectiu (com el pesa, l'evaporacióa, l'índex d'energiab i l'elongaciób) presentaven una alta fiabilitat. Però variables objectiu com l'elongacióa i l'índex de potènciaa tenien greus problemes. Pensem que una de les causes d'aquesta variabilitat és la limitació en el nombre de mostres. En tenir només un conjunt de 36 mostres havíem de recórrer a tècniques com ara la validació creuada per entrenar els models. Qualsevol manca de consistència en la sèrie de dades es podria amplificar i podria provocar prediccions menys fiables. En fer les proves dels models també vam veure que diferents algoritmes tindran diferents capacitats predictives. Així doncs, diferents variables objectiu poden tenir algoritmes més adequats per predir-les. En lloc de trobar l'algoritme perfecte per a totes les variables, pensem que pot ser bo per al dissenyador conèixer aquests diferents graus de fiabilitat. D'aquesta manera poden integrar-los en les eines que utilitzen en el procés de disseny.

#### 7.4. Disseny de la interfície d'usuari

La maqueta inicial que vam crear va ser una eina per facilitar la comunicació entre les diferents persones que treballaven en el projecte. Per exemple, vam descobrir que els predictors actuals (punt llis, tipus de punt i cobertura) són bastant tècnics i el dissenyador del teixit no sol tenir-los en compte. Seria el tècnic en teixits qui traduiria el disseny visual a paràmetres tècnics de teixit. Per tant, amb una eina així, continua sent un interrogant fins a quin punt el dissenyador seria capaç de manipular el disseny.

Un altre dels desafiaments a què vam haver de fer front va ser trobar la quantitat justa de característiques de l'aprenentatge automàtic que havien de quedar obertes a la manipulació de la interfície d'usuari. En la primera maqueta, la majoria dels paràmetres de control quedaven ocults i els algoritmes només mostraven les variables objectiu i les variables predictores. Durant el procés, quan vam descobrir que diferents algoritmes generen resultats amb diferències, vam veure que podria ser valuós per als dissenyadors mostrar els diferents algoritmes, i que, alhora, els permetria analitzar les diferents prediccions i, com a conseqüència, disposar de més creativitat.

Actualment les funcionalitats (variables objectiu) són el resultat de la predicció d'algoritmes d'aprenentatge automàtic. També ens hem plantejat si seria possible invertir el procés i utilitzar les funcions com informació per generar les variables objectiu. En futurs treballs cal tractar aquest tipus d'enfocament més generatiu.

8
CONCLUSIONS

Aquest article ha intentat respondre a la pregunta que defineix la nostra investigació: Com poden aprofitar els dissenyadors el software de disseny intel·ligent per incorporar funcions avançades i personalitzades a productes tèxtils? Per respondre-la hem recorregut a tres subpreguntes:

*1. Quina mena de funcions avançades es poden plantejar incloure en el procés personalitzat de teixidura?*

L'apartat 3.2 descriu el procés seguit per triar les funcions a les quals s'ha d'aplicar la predicció, i la Taula 2 mostra les funcions finals triades. Esperàvem que el cas pràctic (malles de córrer sense costures) fos útil per decidir les funcions i les propietats bàsiques de la tela. I, efectivament, ho va ser perquè ens va ajudar a limitar les variables predictores i les variables objectiu i, alhora, ens va permetre prendre decisions sobre els materials (per exemple, utilitzar només niló i elastà). Tanmateix, quan el projecte estava en una fase més avançada, les limitacions en les capacitats de fer proves, en els recursos de mostratge i en la viabilitat tècnica es van convertir en factors igualment importants. En aquest cas vam descobrir que és millor començar amb un model que tingui poques variables predictores i objectiu. Quan el procés ja està en marxa, i s'entén millor com es relacionen les variables entre si, es poden ampliar les funcions per trobar una coincidència millor amb el cas pràctic.

*2. Com es poden dissenyar interaccions i interfícies que utilitzin algoritmes predictius per estimular la creativitat durant el procés de disseny de moda?*

Una de les decisions crucials va ser establir de quina manera el programa informàtic podia representar la trama de punts. Des del punt de

## ESTUDI DE CAS

## 66

vista del dissenyador, no caldria interactuar directament amb les trames de punts dels tècnics. En lloc d'això seria preferible utilitzar una representació visual abstracta que se centrés en les qualitats funcionals i visuals. No obstant això, perquè l'algoritme funcioni amb més precisió, cal treballar amb representacions de trames i amb variables predictores que s'apropin tant com sigui possible a la tela finalment fabricada. Basant-nos en la nostra anàlisi actual, pensem que en aquest punt hi ha una interessant tensió i que futures investigacions poden ajudar a trobar noves oportunitats. Un dels punts que ens preocupen és com substituir les mostres físiques per mostres virtuals. En eliminar cicles de fabricació física iterativa (que és un dels objectius d'aquest programa informàtic), el dissenyador podria perdre la possibilitat d'inspirar-se gràcies als “accidents” de fabricació. D'altra banda, les noves possibilitats de control i els nous coneixements sobre algoritmes (com per exemple provar diferents algoritmes i models) que tenen els dissenyadors poden ser noves fonts de creativitat que produeixin resultats que no haurien estat possibles amb l'enfocament físic tradicional.

*3. Com influirà el software predictiu en el procés de fabricació d'altres parts implicades i en altres fases de la producció?*

Un dels punts de partida d'aquest estudi va ser el procés de creació del teixit (Fig. 1) que normalment és un procés amb molts passos seqüencials i en què participen diverses persones (el dissenyador de moda, el dissenyador de peces, l'enginyer de teixits i el tècnic de les màquines). No ens proposàvem necessàriament canviar aquest procés, ja que vam admetre que eren necessaris diferents coneixements, especialment en la fabricació avançada. No obstant això, era evident que el programa informàtic començava a apropar el dissenyador i l'enginyer de teixits, probablement més que d'ordinari. Això era així perquè necessitàvem que l'algoritme funcionés amb determinades variables predictores (tipus de punt, estructura de punts) que el dissenyador de peces normalment no seria capaç de controlar. Els dissenyadors de peces normalment creen els seus propis fitxers de trames amb colors i funcions rellevants per al producte final, i els enginyers de teixits i els tècnics de les màquines utilitzen un fitxer de trames codificat en què els colors tenen uns objectius diferents: representar instruccions que les màquines poden entendre. Tal com havia de passar, aquests canvis en les capacitats de cada part implicada podien provocar canvis en els processos i les dinàmiques de treball. Pensem que per a futurs treballs seria oportú avaluar el programa informàtic amb altres parts implicades en el procés de fabricació de teixits. Hem presentat el procés d'aquest estudi de cas com un procés lineal per passos, tot i que el procés real ha estat d'anàlisi iterativa. En incloure en aquest projecte tasques de diferents àmbits que formen part de l'equip (disseny de peces, informàtica i disseny industrial), vam haver d'avançar a poc a poc perquè, a l'inici de cada petit progrés, no quedava mai clar com evolucionaria. Per això esperem que aquest estudi de cas ajudi altres investigadors a preveure els desafiaments que plantegen aquest tipus de projectes multidisciplinaris.

Per acabar, també cal destacar que una gran part de la investigació i del treball de desenvolupament en l'àmbit de la tecnologia de teixits sense costures està patentada i es fa a porta tancada. Esperem que aquest estudi contribueixi a fer més obert i accessible el coneixement en aquest àmbit. Admetem que encara no hi ha una solució definitiva per als processos de prova i els resultats del projecte. Amb tot, aquest estudi és important perquè fa palesa la complexitat que comporta el seu propòsit i ofereix un conjunt de processos per mesurar el rendiment i el comportament dels teixits, i també una forma d'utilitzar aquestes dades per donar forma a un model predictiu.

<p>AGRAÏMENTS</p>
<p>Aquest treball ha tingut el suport de la National Natural Science Foundation de la Xina (NSFC, beca nº 51750110497) i per la Xí'an Jiaotong-Liverpool University (beca nº RDF-13-02-19 i RDF-17-01-54). Volem agrair a Santoni Shanghai la seva generositat, els recursos que ens ha ofert i el suport que ens ha brindat perquè aquest projecte fos possible.</p>
<p>BIOGRAFIES</p>

## M. TEN BHÖMER ET AL.

<p><b>Martijn ten Bhömer</b> Xí'an Jiaotong-Liverpool University</p>
<p><b>Hai-Ning Liang</b> Xí'an Jiaotong-Liverpool University</p>

El Dr. Martijn ten Bhömer és professor del departament de Disseny Industrial, director del màster en Disseny Industrial i director del laboratori de Fabricació Digital de la Universitat de Xí'an Jiaotong-Liverpool. Va fer els seus estudis de doctorat al grup d'investigació Disseny de Qualitat d'interacció del departament de Disseny Industrial de la Universitat Tecnològica d'Eindhoven. Abans d'entrar al departament de Disseny Industrial, el Martijn va adquirir experiència al sector treballant en empreses com ara Microsoft Research (Regne Unit), Deutsche Telekom (Alemanya), OMsignal (Canadà) i Bambi Medical (Països Baixos). En els seus treballs d'investigació va analitzar de quina manera l'aplicació de la filosofia incorporada pot apuntalar el disseny i la fabricació de serveis i productes tèxtils intel·ligents.

<p><b>Difeng Yu</b> Xí'an Jiaotong-Liverpool University</p>
---

Difeng Yu es va graduar amb matrícula en Informàtica a la Universitat Xi'an Jiaotong-Liverpool (XJTLU) el 2018. Actualment és investigador associat del laboratori de realitat virtual de la XJTLU. Els seus estudis d'investigació se centren en la interpretació persona-ordinador. També estudia les tecnologies d'aprenentatge automàtic.

<p><b>Yuanjin Liu</b> Xí'an Jiaotong-Liverpool University</p>
---

Yuanjin Liu va obtenir el títol d'Enginyeria Elèctrica i Automatització amb matrícula a la Universitat Xí'an Jiaotong-Liverpool (XJTLU) el 2017 i el màster en Disseny Industrial amb matrícula en la Universitat de Liverpool el 2019. La seva tesi de màster es va centrar en l'ús del disseny del moviment per potenciar la resposta emocional a productes intel·ligents. Actualment treballa com a dissenyador i investigador en l'àmbit de la interacció persona-ordinador

<p><b>Yifan Zhang</b> Xí'an Jiaotong-Liverpool University</p>
---

Yifan Zhang va obtenir el títol d'Enginyeria Electrònica i Elèctrica amb matrícula a la Universitat de Xí'an Jiaotong-Liverpool el 2014. Va obtenir el màster en Automatització i Control amb matrícula a la Universitat de Newcastle el 2015 i el màster en Disseny Industrial a la Universitat de Liverpool el 2019. La seva tesi es va centrar en la representació visual del comportament humà en el disseny de producte.

<p><b>Eva de Laat</b> <b>Carola Leegwater</b> Eva x Carola</p>
--

Eva x Carola és un estudi de disseny creat per Carola Leegwater i Eva de Laat. Les dues dissenyadores es van especialitzar en Direcció de Moda i Producció Internacional en el prestigiós Amsterdam Fashion Institute. Després de graduar-se, l'Eva i la Carola van treballar a Nike, la marca de roba esportiva, on van desenvolupar i crear productes per a competicions d'àmbit internacional com el Tour de França, la Copa Mundial de la FIFA i els Jocs Olímpics. Actualment Eva x Carola destaquen en la indústria de la roba esportiva per la investigació, el desenvolupament i la creació de materials tèxtils d'última generació que, a banda d'oferir prestacions úniques quant a benestar i sostenibilitat, es personalitzen segons les necessitats de cada atleta. El duet, que recentment ha estat nominat als premis Future Textiles Awards, col·labora amb empreses com Santoni Shanghai, Lenzing i Woolmark creant roba d'esport innovadora que s'aparta del disseny convencional i proposa alternatives de futur i intel·ligents.

<p>FIGURES I TAULES</p>
-------------------------

**Fig. 1.** Passos que normalment se segueixen en el procés de disseny de peces de roba (fotos del projecte CRISP, Universitat Tecnològica d'Eindhoven). En aquest projecte en concret es va utilitzar una màquina de teixit pla, a diferència de les màquines de teixit circular que s'han utilitzat en aquest article..

**Fig. 2.** Projecte d'exemple de peça de roba sense costures dissenyada per l'equip de disseny de peces del projecte i fabricada amb màquines de teixit circular. El sostenidor d'esport combina diverses textures funcionals: 1) Estructures obertes per oferir transpirabilitat; 2) Zones rígides per corregir la postura; 3) Estructures texturades per a la circulació de l'aire; i 4) Zones de punts més atapeïts i menys densos per crear zones de confort i elasticitat per una banda i zones rígides per l'altra. El sostenidor, per naturalesa, és una peça extremadament personal. Pot variar en molts aspectes, no només en la seva funció, la seva mida i el seu estil, sinó també en la manera de dur-lo i en el

## 67





calcetería, que con la creación de máquinas de cuerpo circular adaptó las máquinas de calcetería de pequeño diámetro, como las de Santoni (Black 2002). La tecnología de punto circular ha evolucionado y ahora permite a los diseñadores crear elegantes prendas pegadas a la piel y ropa de deporte activa (Fig. 2). Con esta tecnología se pueden crear, directamente a partir de hilos y sin ningún tipo de costura, prendas tubulares en tres dimensiones (3D) listas para usar: ropa interior, ropa de baño o ropa de deporte (Lau y Yu 2016).

#### 2.2. Funciones para correr

Para facilitar la toma de decisiones del proyecto decidimos elegir un tipo de producto que es muy habitual entre las prendas de punto circular, pero que presenta complejos desafíos de diseño porque es difícil prever sus funciones en la fase de diseño. Estamos hablando de las mallas de correr. Correr es un proceso complejo y coordinado en el que participa todo el cuerpo. Su característica principal es que ambos pies están al mismo tiempo elevados del suelo. En función de la distancia, hay varias modalidades de carrera: velocidad, media distancia y larga distancia. En velocidad, las distancias habituales son 60 m, 100 m, 200 m y 400 m. En estas distancias los atletas necesitan acumular una gran cantidad de fuerza en poco tiempo, lo que representa una fuerte presión para los músculos, especialmente los de las piernas. Por ejemplo, el músculo cuádriceps estabiliza la rodilla e impide que se doble hacia adelante, mientras que los tendones y los gastrocnemios impiden la rotación y la extensión de la tibia (Slocum y James 1968). Basándonos en esta información sobre la biométrica que implica la actividad de correr, se puede deducir que las distintas partes de la ropa que lleva un velocista tendrán necesidades funcionales distintas.

#### 2.3. Aprendizaje automático

El presente proyecto tiene por objetivo predecir las funciones de un producto textil fabricado sin tener que fabricarlo. Para ello, uno de los métodos más conocidos y potentes es el aprendizaje automático. Gracias al uso de ordenadores, el aprendizaje automático nos permite predecir ciertos resultados o nuevas muestras «entrenando» a modelos matemáticos con datos de ejemplo o casos anteriores (Alpaydin 2014). El modelo que ha recibido la formación puede generar predicciones exactas o tomar decisiones sin ser expresamente programado para realizar dicha tarea (Bishop 2006). A causa de su utilidad, el aprendizaje automático se ha utilizado profusamente en muchos ámbitos como la sanidad, la detección del fraude, las recomendaciones personalizadas, etc. En este proyecto trabajamos con varias técnicas de aprendizaje automático, como los modelos lineal, no lineal y de árbol, para predecir distintas variables objetivo a partir de pruebas empíricas. Seguiremos los tres grandes pasos que se aplican en los algoritmos de aprendizaje automático: 1) recogida y preparación de datos; 2) generación, evaluación y selección del modelo; 3) predicción (Kuhn 2013).

#### 2.4. Estructura del artículo

El capítulo 3 describe cómo generamos el modelo de datos seleccionando variables objetivo y variables predictoras importantes que son la base del software predictivo. El capítulo 4 sigue con el proceso de recogida y preparación de datos, que incluye el desarrollo y la fabricación de muestras físicas así como procedimientos de prueba para crear una serie de datos. En el capítulo 5, Construir, evaluar y seleccionar los modelos de aprendizaje automático, se comparan varios algoritmos en función de su capacidad de predecir las variables objetivo. El capítulo 6 muestra la creación de un prototipo de interfaz de usuario que permite a los diseñadores de tejidos recibir en tiempo real información de los algoritmos de aprendizaje automático. El capítulo 7 describe importantes hallazgos que se pusieron de manifiesto durante el proyecto. Por último, el capítulo 8 cierra con una reacción a las preguntas iniciales de la investigación.

3
EL MODELO DE DATOS

El objetivo del modelo de datos es relacionar información anterior sobre el diseño de la tela con las propiedades funcionales del producto tejido realmente fabricado. En nuestro modelo de datos expresamos estas dos partes con variables predictoras (los parámetros que pueden influir potencialmente en el resultado) y variables objetivo (el resultado esperado).

## TEMES DE DISSENY #35

#### 3.1. Variables predictoras

La principal característica de la tecnología de punto circular es que toda su producción está condicionada a una forma tubular. Las variaciones en la forma y las funciones se pueden introducir con cambios en los materiales (el hilo) y en la estructura (determinados puntos) de dicho tubo (Matkovic 2010). Estas variaciones suelen expresarse con patrones que se pueden convertir en instrucciones que una máquina puede leer (la Fig. 3 muestra un ejemplo de este tipo de patrones).

Para simplificar el modelo de datos de la primera prueba de nuestro método, decidimos limitar la variación de materiales y centrarnos en la combinación de distintas estructuras de tejido. En los materiales decidimos trabajar con dos hilos básicos que se utilizan habitualmente en prendas de deporte: elastano (fabricado con una fibra sintética de excepcional elasticidad) y nailon. Tal como muestra la Tabla 1, para hacer variaciones de las estructuras de tejido definimos tres parámetros que servirían como variables predictoras: el tipo de punto, la estructura de puntos y la cobertura del tubo.

Tipo de punto

Para las variaciones en las estructuras elegimos tres tipos básicos de punto: malla retenida, basta, y malla cargada (Spencer 2001). Antes de mostrar las diferencias entre estos tres tipos de puntos, puede ser útil mostrar el punto liso, que es el punto más elemental y se puede considerar la unidad básica del entrelazado. Suele estar formado por tres o más mallas entrelazadas (Fig. 4a). Es la estructura básica de la calcetería femenina, de las prendas que se adaptan a la forma del cuerpo y de las telas de punto liso. La malla retenida (Fig. 4b) se obtiene cuando una aguja que sostiene una malla deja pasar el siguiente hilo y une las dos mallas más próximas que teje. La basta (Fig. 4c) produce un calado abierto en telas de punto liso y comporta el uso de dos hilos para el vanisado. Esta estructura se ha utilizado en telas anticarreras para medias, diseños texturizados y calados para ropa interior. La malla cargada (Fig. 4d) se forma cuando una aguja sostiene una malla y recibe un nuevo hilo. La malla tejida que se forma primero se denomina malla base y la malla que se le une es la malla cargada.

Estructura de puntos

Otra variable importante que puede predecir la funcionalidad final y el rendimiento de la tela es la estructura que se crea con los tipos de punto. La estructura determina el tamaño del punto en la tela. Por ejemplo, una estructura de 1 x n bastas está formada por una malla fija y n bastas. Como referencia, la Figura 5a muestra una estructura de punto liso y tres variedades de bastas: 1 x 1 basta (Fig. 5b), 1 x 2 bastas (Fig. 5c) y 1 x 3 bastas (Fig. 5d). Para reducir la complejidad de nuestra serie de datos, no incluimos estructuras de puntos mayores de 1 x 3. Cuando se teje una tela, cada tipo de punto se puede combinar con distintas estructuras de puntos para crear determinadas funciones. Por ejemplo, una estructura de puntos más grande con bastas dará lugar a una estructura abierta, que al mismo tiempo dará lugar a una mayor circunferencia del tubo final.

Tube Coverage

La tercera variable predictiva es la cobertura de la estructura de puntos en el tubo de tela tejida. Una prenda puede estar formada por varias áreas estructurales, que desempeñan un papel importante para definir las funciones. Por ejemplo, una camiseta deportiva puede tener mayor compresión alrededor del tríceps para facilitar la recuperación de la musculatura y al mismo tiempo pueden presentar una estructura abierta en las axilas para el tratamiento de la temperatura durante el ejercicio. Para reducir la complejidad, decidimos que en cada tela solo combinaríamos un tipo de punto con el punto liso. Por otra parte, en lugar de crear telas de varias formas decidimos trabajar solo en una área rectangular de un tipo concreto de punto y de estructura. Simplificamos aún más estas variabilidades estructurales eligiendo cuatro diseños distintos de estructura tubular de la tela: 25%, 50%, 75% y 100% (como se ve en la Fig. 6). Por ejemplo, una cobertura del 25% de la estructura con 1 x 1 basta significa que el 25% de la superficie del tejido en forma de tubo está cubierta con 1 x 1 basta, y el 75% restante, con punto liso.

## ESTUDIO DE CASO

## 70

#### 3.2. Variables objetivo

Las prendas compresivas, aquellas prendas que se pueden crear con elastano y nailon, son muy utilizadas por atletas y gimnastas. Entre los atletas, estas prendas tienen el propósito principal de ofrecer una mejor recuperación y un mayor rendimiento (Hill et al. 2014). Aunque la investigación todavía no es concluyente, sugiere que las prendas compresivas pueden mejorar la sensibilidad de las articulaciones, el flujo sanguíneo local, la eliminación de residuos, la gestión de carrera, y reducir la sudoración, las oscilaciones musculares y el dolor muscular post-ejercicio (Born, Sperlich y Holmberg 2013). Así pues, la ropa que llevan los atletas debería presentar un buen rendimiento en funciones como la compresión, el confort, la recuperación, la absorción capilar, la transpiración, la permeabilidad al aire, etcétera. Por tanto, las variables objetivo que el diseñador de estos tipos de ropa debería analizar están relacionadas con las funciones que ofrecen las prendas compresivas. Tuvimos en cuenta varias funciones durante el proceso:

- Absorción capilar (medida utilizando el test de absorción, que consiste en medir la distancia que puede avanzar el agua por una pieza de ropa colgando).
- Grado de roce (medido utilizando el coeficiente de fricción, un plano inclinado para medir la fuerza que necesita un peso para resbalar por encima de la tela).
- Absorción (midiendo la velocidad de absorción del agua).
- Permeabilidad (medida con el método de la copa hacia arriba: utilizar la tela a modo de membrana para ver cuánta agua entra en la copa).
- Aislamiento (se podría medir con una placa eléctrica o con un maniquí térmico).
- Compresión (midiendo la elongación en la tela provocada por un determinado peso).
- Sensación de confort (medida con cuestionarios homologados y escalas de valoración de reacciones a la tela).

Terminamos creando una lista resumen de variables objetivo (Tabla 2). La elección de las variables objetivo fue un equilibrio entre las capacidades de medición y las instalaciones del laboratorio por una parte y la decisión de determinar la prioridad de las funciones más importantes por la otra parte:

Parámetros básicos

Los parámetros básicos pueden ayudar a los diseñadores a evaluar las propiedades básicas de la tela diseñada para una prenda. Puesto que cada tela tendrá propiedades distintas a causa de las diferencias en el tipo de punto, la estructura y la cobertura, el diseñador por norma general no conoce exactamente las propiedades del producto fabricado final. El peso y el diámetro de la tela de tubo son dos variables principales que elegimos como objetivo.

Parámetros dinámicos

Las prendas compresivas pueden reducir los síntomas asociados a lesiones musculares mediante ayuda mecánica al tejido dañado y una reducción en el movimiento del miembro. La variable de la fuerza de descarga indicará la energía que la prenda transmite al cuerpo. Que se mantenga la presión constante sobre el cuerpo humano depende de la elasticidad de la prenda compresiva, que se puede medir con la variable objetivo de la elongación. La transferencia de humedad de la tela también puede influir en el confort fisiológico. Si la transpiración supera a la capacidad de absorción, el usuario puede sentir incomodidad. Por eso se eligió la evaporación como variable objetivo para valorar esta función.

Índice de rendimiento

Para comparar nuestras variables objetivo utilizamos una tercera categoría de variables objetivo que nos proporcionó un auditor homologado. El índice de rendimiento es una herramienta de la cadena de suministro que puede favorecer la comunicación entre los distintos actores, ya que promete una escala cuantitativa objetiva para varios parámetros de las telas (INVISTA Apparel & Advanced Textiles 2017). El índice de rendimiento se obtiene a partir de tres valores: el índice de potencia, el índice de energía y el índice de confort. El índice de potencia mide el factor de rendimiento de las telas en una escala de uno a diez. El índice de confort mide la capacidad que tienen de actuar a modo de «segunda piel» y permitir libertad de movimiento. El índice de energía indica la energía que absorbe la prenda en movimiento.

## M. TEN BHÖMER ET AL.

4
RECOGIDA Y PREPARACIÓN DE DATOS

Para entrenar a los algoritmos de aprendizaje automático, hubo que crear una serie de datos en la que los algoritmos basaran sus predicciones. La creación de estos datos de entrenamiento constó de dos partes. En primer lugar hubo que crear muestras físicas de tela con distintas combinaciones de variables predictoras. En segundo lugar hubo que elaborar un conjunto de protocolos de prueba para evaluar el rendimiento de las variables objetivo con dichas muestras.

#### 4.1. Fabricación de las muestras de tela

WUtilizamos máquinas de tejer circulares con las que fabricamos 36 telas de estructura tubular (la Fig. 7 muestra una de ellas) que cubren todas las variaciones de variables predictoras posibles (la Tabla 3 muestra todas las combinaciones, mientras que la Tabla 4 muestra las muestras físicas ordenadas por variación).

#### 4.2. Pruebas de las muestras de tela

Antes de hacer las pruebas de elongación y evaporación, se midió el pesoa de cada muestra. Se utilizó una balanza electrónica para las mediciones de las distintas muestras. La elongacióna se midió ejerciendo una fuerza de tracción de un kilogramo a las muestras tubulares. La elongación se midió con una regla, y la magnitud de la variación se calculó dividiendo la longitud inicial por la longitud al ejercer la fuerza. La evaporacióna se midió esparciendo un mililitro de agua destilada en la zona analizada de la prenda y registrando el tiempo que tarda en evaporarse. Especialmente durante esta prueba se vio claramente que es difícil generalizar la medición de una función localizada (evaporación) a toda la tela tubular. Por ejemplo, al medir la evaporación de una tela de malla cargada 1 x 2 (50% de cobertura), el valor de evaporación podía variar enormemente entre la parte de punto liso y la parte de malla cargada 1 x 2. Por eso decidimos calcular la evaporación como una ponderación de los valores de las distintas partes. Por ejemplo, en el caso anterior de tela tubular de malla cargada 1 x 2 (50% de cobertura) el valor de evaporación fue de 12 minutos en la zona de punto liso y de 8 minutos en la zona de malla cargada 1 x 2. El valor ponderado, pues, fue de 10 minutos (12 \* 0,5 + 8 \* 0,5). La medición de las variables objetivo de elongaciónb, diámetro de prendab, fuerza de descargab, así como las tres variables del índice de rendimiento (índice de potenciab, índice de energíab e índice de confortb) se llevó a cabo en un laboratorio externo con métodos de medición homologados. La Tabla 5 muestra los resultados de las pruebas.

5
APRENDIZAJE AUTOMÁTICO: ELABORACIÓN DEL MODELO, EVALUACIÓN Y SELECCIÓN

Para configurar la relación entre las variables predictoras y las variables objetivo, comparamos ocho algoritmos, que se pueden dividir en tres grupos: modelos de regresión lineal, modelos de regresión no lineal y modelos de árbol. Los modelos lineales hacen una predicción utilizando una función lineal de los predictores. Son sencillos y más fáciles de interpretar pero pueden presentar una respuesta pobre ante series de datos complejas. Los tres modelos lineales que probamos son: regresión lineal, regresión robusta y red elástica. Los modelos no lineales son más potentes porque se adaptan a más tipos de curvas que las relaciones lineales, pero suelen ser menos interpretables y más difíciles de entrenar. Probamos los siguientes modelos no lineales: splines de regresión adaptativa multivariante (MARS, por sus siglas en inglés), redes neuronales, y máquinas de vectores de soporte (SVM, por sus siglas en inglés). Los modelos de árbol están entre los más utilizados en el aprendizaje automático porque su uso es fácil y pueden comprender relaciones no lineales complejas. Un punto en su contra es que tienden a memorizar el ruido que hay en una serie de datos. Los algoritmos de árbol que probamos son: bosques aleatorios (random forests) y árboles potenciados (boosted trees). Siguiendo las tesis de Kuhn et al. (2013) aplicamos distintas técnicas de preprocesado a los algoritmos recién indicados, tal como se indica en la Tabla 6.

Dos métodos para medir la eficacia de los algoritmos son el del error cuadrático medio (Root-Mean-Square Error, RMSE) y el del coeficiente de

## 71

determinación (R2). RMSE es el error cuadrático medio de las diferencias entre los valores que predice un modelo y los valores realmente observados. Se utiliza habitualmente para medir el grado de exactitud, para comparar errores de predicción de distintos modelos en una variable objetivo concreta. R2 es otro parámetro que utilizamos para evaluar los algoritmos, ya que se puede interpretar como la proporción de la información contenida en los datos que el modelo puede comprender. Al ser una correlación, R2 tiene la ventaja de que no se rige por ninguna escala. Es decir, independientemente de si la escala del resultado es grande o pequeña, el valor de R2 estará entre 0 y 1. Por norma general, un RMSE bajo y un R2 alto indican que el modelo es adecuado para la variable objeto.

Preparamos los ocho modelos que acabamos de presentar y los evaluamos en dos análisis. El primer análisis fue con los datos obtenidos con las pruebas realizadas en nuestro laboratorio (pesoa, elongacióna y evaporacióna) y el segundo, con los datos obtenidos en las pruebas del laboratorio externo (índice de potenciab, índice de confortb, índice de energíab, fuerza de descargab, elongaciónb y diámetro de prendab). Tras la evaluación, seleccionamos los modelos definitivos.

*5.1. Primer análisis*

En esta primera prueba, ajustamos los modelos y comprobamos su rendimiento en cinco repeticiones de validación cruzada de 10 iteraciones (Kuhn et al. 2013). La validación cruzada es una técnica que se utiliza para calcular el rendimiento de un modelo. Consiste en dividir la muestra original en datos de entrenamiento y datos de validación (llamados también datos de prueba). Los resultados se expresan en forma de líneas en coordenadas paralelas que muestran los resultados que dan los ocho modelos para distintas secuencias. Vimos que ciertos modelos (árboles potenciados, bosque aleatorio, MARS y las redes neuronales) se adaptan mejor a los objetivos de pesoa (Fig. 8) y evaporacióna (Fig. 9). Sin embargo, las predicciones no siempre son estables (en ocasiones el rendimiento del modelo sufría una brusca caída). Ello podría deberse a que la muestra era de un tamaño no muy grande. Además, los datos que se generaron en las pruebas podrían tener problemas de consistencia. En el objetivo de elongacióna (Fig. 10) todos los modelos tuvieron problemas para predecir el valor. Nuestra hipótesis es que los predictores no se correlacionaban bien con los objetivos.

*5.2. Segundo análisis*

En el segundo análisis, utilizamos los objetivos que se crearon en el laboratorio externo. Se utilizaron repeticiones de validación cruzada de 10 iteraciones para ajustar y evaluar los distintos modelos. Siguiendo este procedimiento, vimos que la predicción que hacía el algoritmo de árboles potenciados daba resultados prometedores en los valores del índice de energíab (Fig. 11) y de elongaciónb (Fig. 12). El modelo se mostró robusto en la predicción de resultados para ambas variables. En el índice de confortb (Fig. 13), la fuerza de descargab (Fig. 14) y el diámetro de prendab (Fig. 15) los resultados mostraban un buen comportamiento en la mayoría de secuencias, pero en ocasiones el modelo tenía muchas dificultades para lograr su objetivo. Los resultados de la predicción del índice de potenciab no fueron tan buenos (Fig. 16). Ello se podría deber a que la serie de datos solo contiene los valores 2 y 3, y no es fácil clasificar esos dos objetivos a partir de los predictores.

*5.3. Selección final de modelon*

En base a estos dos análisis, seleccionamos seis modelos tras eliminar la regresión robusta y la red elástica, ya que ambas tenían un bajo rendimiento con la regresión lineal. Los resultados finales de la evaluación (que muestran la Tabla 7 y la Tabla 8) se obtuvieron mediante validación cruzada dejando uno fuera (Leave-One-Out Cross-Validation, LOOCV), que encaja más con las muestras de entrenamiento que la validación cruzada con 10 iteraciones para un cálculo con remuestreo.

6
DISEÑO DE LA INTERFAZ DE USUARIO

El diseño de la interfaz de usuario fue un proceso en colaboración con los diseñadores de tejidos, que fueron quienes terminaron utilizando la interfaz. En el proceso primero intentamos comprender los requisitos, luego construimos una maqueta de la interfaz y por último creamos los

## TEMES DE DISSENY #35

algoritmos de aprendizaje que funcionan con datos de entrenamiento y generamos un prototipo.

- 6.1. Comprender los requisitos*

Antes de empezar con el diseño de la interfaz era necesario comprender el papel que pueden desempeñar en el proceso de diseño de los géneros de punto las habilidades predictivas de esta herramienta. Preguntamos a nuestros socios diseñadores de tejidos cómo era su proceso en aquel momento y qué herramientas utilizaban en cada paso del proceso. En resumen, el proceso incluye las fases siguientes:

  - Creación del concepto en base a la línea visual, inspirándose en tramas y gráficos (por ejemplo, manipulando y combinando tramas).
  - Creación de una biblioteca de tramas. Varias tramas que se pueden probar con distintas combinaciones de puntos y que mediante el método de tanteo y error pueden obtener la función correcta.
  - Valoración subjetiva de los aspectos visual y funcional de los resultados de las pruebas, y mapeado de los mismos sobre el cuerpo. En este paso se pueden utilizar mediciones objetivas.
  - Combinación de las tramas mapeadas sobre el cuerpo en un diseño completo de prenda.
  - Creación de un fichero de cuadrícula en el que ambas caras coincidan (para crear una forma tubular).
  - Inicio del proceso de ingeniería para convertir el diseño en una forma en 3D.

Basándonos en este proceso, nuestro propósito inicial era utilizar la herramienta correspondiente al paso que normalmente necesita pruebas iterativas (paso b). La herramienta debería ofrecer al diseñador la posibilidad de evaluar y analizar los cambios en la funcionalidad, sin tener que tejer físicamente cada muestra. Eso permitiría una mayor velocidad en los análisis y una mayor flexibilidad en el proceso exploratorio. El principal punto de partida de este proceso son las tramas visuales que ya se diseñaron en el paso a. Así pues, la herramienta debería ser capaz de utilizar las tramas visuales como material de trabajo y permitir a los diseñadores hacer variaciones de las estructuras de puntos para determinar los valores de las funciones.

- 6.2. Maqueta de la interfaz de usuario*

En base a las líneas fijadas en la fase de requisitos, se creó una maqueta con el programa Wireframes de Balsamiq (Balsamiq s.f.). La interfaz principal (Fig. 17) está formada por el lienzo para tramas, el panel de resultados de predicción y una biblioteca de muestras de tramas. El lienzo de tramas carga una trama visual de vectores y separa los distintos objetos en capas diferentes que se superponen en el lienzo. El panel de ajustes de propiedades muestra una visión general de los resultados de la predicción para el caso de la tela diseñada. La biblioteca de muestras de tramas permite que los usuarios reutilicen tramas creadas anteriormente. Haciendo clic en una de las tramas se abrirá la ventana del diseño de la trama (Fig. 18.a). Desde esta ventana el diseñador puede modificar los parámetros del tejido, como el tipo de punto o la estructura de puntos. La ventana muestra una representación visual de cómo será la trama de puntos, así como un resumen de la predicción de los valores de las distintas funciones (transpiración, elongación, peso, evaporación, etc). Cuando el usuario confirma la trama, esta queda grabada en la biblioteca de muestras de tramas. Por último, se puede cargar una forma en el lienzo (Fig. 18.b). Al seleccionar la forma y hacer clic en una muestra de la biblioteca de muestras de tramas, el programa mostrará la visualización de la trama en el lienzo. Al mismo tiempo, el panel de resultados de predicciones actualizará los valores para la tela diseñada.

- 6.3. Creación del prototipo*

Al crear la maqueta vimos que la serie de datos que teníamos no permitía traducir las tramas visuales en valores de predicción. En nuestra serie de datos trabajábamos con porcentajes de cobertura del tubo, que presupone que toda una zona de la tela está cubierta con un tipo de punto concreto y una estructura de puntos determinada. Así pues, decidimos aplicar únicamente los cambios en el porcentaje de cobertura del tubo en lugar de implementar el diseño de tramas visuales determinadas. El prototipo se creó con Unity (Unity s.f.), un programa informático que se suele utilizar para programar juegos, pero que también puede crear prototipos de interfaces en 2D. La interfaz principal de la herramienta (Fig. 19) se dividió en dos áreas principales. La zona de diseño de la trama muestra la representación de una tela mediante un rectángulo con dos partes.

## ESTUDIO DE CASO

El diseñador puede desplazar una línea para modificar el porcentaje de cobertura. Mediante las listas desplegables se pueden adaptar el tipo de punto y la estructura de puntos. Cuando se manipulen los valores de la trama, el programa calculará en tiempo real la predicción de los valores de las funciones y los presentará en la tabla de valores de predicción de la parte derecha de la interfaz. El diseñador puede alternar entre los distintos algoritmos de aprendizaje automático para ver cómo cambiaría la predicción de los valores de las variables objeto. El programa también muestra el grado de fiabilidad en forma de estrellas de colores, basándose en los valores RMSE y R². De ese modo el diseñador puede decidir el diseño en función de la fiabilidad de las funciones previstas.

7
HALLAZGOS

Durante el proyecto aprendimos muchas cosas importantes, y en nuestra opinión pueden ser útiles para otras personas que sigan este enfoque. La clasificación de los hallazgos se corresponde con la clasificación de los distintos puntos de las partes del proceso que se han descrito anteriormente.

- 7.1. El modelo de datos*

Uno de los principales desafíos que planteaba la definición del modelo de datos era decidir los valores de los predictores y de los objetivos. Ello significaba que había que simplificar partes de los parámetros del tejido e incluso ignorar algunos. Por ejemplo, decidimos utilizar únicamente dos tipos de hilo: nylon y elastano. Los materiales pueden influir enormemente en las propiedades finales de la tela. Incluso un mismo material con distintos tintes puede reaccionar de maneras diferentes. Utilizar distintos materiales también complica el proceso de fabricación, porque hay que corregir la configuración de la máquina para cada hilo. Decidimos eliminar la mayoría de estas variabilidades y mantener el material constante. Utilizamos el porcentaje de cobertura del tubo para indicar distintas tramas, en lugar de utilizar gráficos que representen tramas visuales de puntos. Normalmente las prendas de punto se diseñan creando tramas visuales (Fig. 3). Simplificamos este punto por dos motivos. 1) No había un lenguaje visual uniforme de tramas de puntos. Al exportar los distintos ficheros de datos de tramas de puntos vimos que, en distintos tipos de programas y máquinas de tejido circulares, un mismo color podía tener significados similares y las tramas podían presentar tamaños distintos. 2) Los diseños visuales que suelen crear los diseñadores de prendas de punto son altamente complejos y contienen demasiadas variables. No teníamos los recursos necesarios para crear una serie de datos suficientemente grande como para entrenar a los algoritmos en base a dichas variabilidades.

- 7.2. Recogida y preparación de datos*

El principal desafío que planteaba la recogida y preparación de datos era el de obtener los datos de prueba necesarios para los algoritmos de aprendizaje. Aunque habíamos planeado multitud de pruebas, solo pudimos hacer pruebas básicas en nuestro laboratorio interno. Tuvimos que recurrir a un laboratorio externo para las pruebas de funciones añadidas. Una de las desventajas de este planteamiento es que los métodos de prueba no eran nuestros y no conocíamos ni su procedimiento ni su calidad. Surgió un problema cuando tuvimos que hacer pruebas a estructuras tubulares. Las telas tubulares, por naturaleza, no tienen ni principio ni fin. Por eso se hace especialmente complicado idear métodos de prueba que se supone que deben medir la función de toda la tela. Por ejemplo, cuando hicimos pruebas de evaporación, ¿eran pruebas de evaporación de la tela en su conjunto o solo de la zona que tenía un tipo de punto específico y una estructura de puntos determinada? Al final decidimos recurrir a un planteamiento híbrido. En el caso de la evaporacióna medimos la proporción de las estructuras de puntos respecto de la estructura de punto liso. En cuanto a la elongacióna medimos el estiramiento de todo el tubo de tela.

- 7.3. Aprendizaje automático: elaboración del modelo, evaluación y selección*

Comparamos varios algoritmos de aprendizaje automático para determinar su capacidad de predecir las variables objetivo. Algunas variables objetivo (como el pesoa, la evaporacióna, el índice de energíab y la elongaciónb) presentaban una alta fiabilidad. Pero variables objetivo como la elongacióna y el índice de potenciaa tenían graves problemas. Creemos

## M. TEN BHÖMER ET AL.

que una de las causas de esta variabilidad es la limitación en el número de muestras. Al tener solo un conjunto de 36 muestras tenfamos que recurrir a técnicas como la validación cruzada para entrenar a los modelos. Cualquier falta de consistencia en la serie de datos se podría amplificar y podría provocar predicciones menos fiables. Al realizar las pruebas de los modelos también vimos que distintos algoritmos tendrán distintas capacidades predictivas. Por consiguiente, distintas variables objetivo pueden tener algoritmos más adecuados para predecirlas. En lugar de encontrar el algoritmo perfecto para todas las variables, creemos que puede ser bueno para el diseñador conocer estos distintos grados de fiabilidad. De ese modo pueden integrarlas en las herramientas que utilizan en el proceso de diseño.

- 7.4. Diseño de la interfaz de usuario*

La maqueta inicial que creamos fue una herramienta para facilitar la comunicación entre las distintas personas que trabajaban en el proyecto. Por ejemplo, descubrimos que los predictores actuales (punto liso, tipo de punto y cobertura) son bastante técnicos y el diseñador del tejido no suele tenerlos en cuenta. Sería el técnico en tejidos, el que traduciría el diseño visual a parámetros técnicos de tejido. Por tanto, con una herramienta así, sigue siendo un interrogante hasta qué punto sería capaz el diseñador de manipular el diseño. Otro de los desafíos que tuvimos que abordar fue encontrar la cantidad justa de características del aprendizaje automático que debían quedar abiertas a la manipulación en la interfaz de usuario. En la primera maqueta, la mayoría de parámetros de control quedaban ocultos y los algoritmos solo mostraban las variables objetivo y las variables predictoras. Durante el proceso, cuando descubrimos que distintos algoritmos generan resultados con diferencias, vimos que podría ser valioso para los diseñadores mostrar los distintos algoritmos, y que, al mismo tiempo, les permitiría analizar las distintas predicciones y, por consiguiente, disponer de una mayor creatividad.

Actualmente las funcionalidades (variables objetivo) son el resultado de la predicción de algoritmos de aprendizaje automático. Nos hemos planteado también si sería posible invertir el proceso y utilizar las funciones como información para generar las variables objetivo. En futuros trabajos hay que abordar este tipo de enfoque más generativo.

8
CONCLUSIONES

El presente artículo ha intentado responder a la pregunta que define nuestra investigación: ¿Cómo pueden aprovechar los diseñadores el software de diseño inteligente para incorporar funciones avanzadas y personalizadas en productos textiles? Para contestar hemos recurrido a tres subpreguntas:
1. *¿Qué tipo de funciones avanzadas se puede plantear incluir en el proceso personalizado de tejido?*

El apartado 3.2 describe el proceso seguido para elegir las funciones a las que aplicar la predicción, y la Tabla 2 muestra las funciones finales elegidas. Esperábamos que el caso práctico (mallas de correr sin costuras) fuera de ayuda para decidir las funciones y las propiedades básicas de la tela. Y, efectivamente, fue útil porque nos ayudó a limitar las variables predictoras y las variables objetivo y, al mismo tiempo, nos permitió tomar decisiones sobre los materiales (por ejemplo, utilizar únicamente nylon y elastano). Sin embargo, cuando el proyecto estaba en una fase más avanzada, las limitaciones en las capacidades de hacer pruebas, en los recursos de muestreo y en la viabilidad técnica se convirtieron en factores igualmente importantes. En este caso descubrimos que es mejor empezar con un modelo que tenga pocas variables predictoras y objetivo. Cuando el proceso ya está en marcha, y se comprende mejor cómo se relacionan entre sí las variables, se pueden ampliar las funciones para encontrar una mejor coincidencia con el caso práctico.

- ¿Cómo se pueden diseñar interacciones e interfaces que utilicen algoritmos predictivos para estimular la creatividad durante el proceso de diseño de moda?*

Una de las decisiones cruciales fue decidir cómo podía el programa informático representar la trama de puntos. Desde el punto de vista del diseñador, no sería necesario interactuar directamente con las tramas de puntos de los técnicos. En lugar de eso sería preferible utilizar una representación visual abstracta que se centrara en

## 73



las cualidades funcionales y visuales. No obstante, para que el algoritmo funcione con más precisión, es necesario trabajar con representaciones de tramas y con variables predictoras que se acerquen al máximo a la tela finalmente fabricada. Basándonos en nuestro análisis actual, creemos que en este punto existe una interesante tensión y que futuras investigaciones pueden ayudar a encontrar nuevas oportunidades. Uno de los puntos que nos preocupan es cómo sustituir las muestras físicas por muestras virtuales. Al eliminar ciclos de fabricación física iterativa (que es uno de los objetivos de este programa informático), el diseñador podría perder la posibilidad de inspirarse gracias a los “accidentes” de fabricación. Por otra parte, las nuevas posibilidades de control y los nuevos conocimientos sobre algoritmos (como por ejemplo probar distintos algoritmos y modelos) que tienen los diseñadores pueden ser nuevas fuentes de creatividad que produzcan resultados que no habrían sido posibles con el enfoque físico tradicional.

### 3. ¿Cómo influirá el software predictivo en el proceso de fabricación de otras partes implicadas y en otras fases de la producción?

Uno de los puntos de partida de este estudio fue el proceso de creación del tejido (Fig. 1), que normalmente es un proceso con muchos pasos secuenciales y en el que participan varias personas (el diseñador de moda, el diseñador de prendas, el ingeniero de tejidos y el técnico de las máquinas). No nos proponíamos necesariamente cambiar este proceso, pues admitimos que hacen falta distintos conocimientos, especialmente en la fabricación avanzada. No obstante, era evidente que el programa informático empezaba a acercar al diseñador y al ingeniero de tejidos, probablemente más que de costumbre. Eso era así porque necesitábamos que el algoritmo funcionara con determinadas variables predictoras (tipo de punto, estructura de puntos) que el diseñador de prendas normalmente no sería capaz de controlar. Los diseñadores de prendas normalmente crean sus propios ficheros de tramas con colores y funciones relevantes para el producto final, y los ingenieros de tejidos y los técnicos de las máquinas utilizan un fichero de tramas codificado, en el que los colores tienen un objetivo distinto: representar instrucciones que las máquinas puedan entender. Como no podía ser de otro modo, estos cambios en las capacidades de cada parte podían provocar cambios en los procesos y las dinámicas de trabajo. Creemos que para futuros trabajos sería oportuno evaluar el programa informático con otras partes implicadas en el proceso de fabricación de tejidos. Hemos presentado el proceso de este estudio de caso como un proceso lineal por pasos, aunque el proceso real ha sido de análisis iterativo. Al incluir este proyecto tareas de distintos ámbitos que forman parte del equipo (diseño de prendas, informática y diseño industrial), tuvimos que avanzar despacio porque, al empezar cada pequeño avance, nunca quedaba claro cómo iba a evolucionar. Por eso esperamos que este estudio de caso ayude a otros a prever los desafíos que plantean este tipo de proyectos multidisciplinarios.

Por último, también hay que destacar que gran parte de la investigación y del trabajo de desarrollo en el ámbito de la tecnología de tejidos sin costuras está patentada y se produce a puerta cerrada. Esperamos que este estudio contribuya a hacer más abierto y accesible el conocimiento en este ámbito. Admitimos que todavía no hay una solución definitiva para los procesos de prueba y los resultados del proyecto. Con todo, este estudio es importante porque pone de manifiesto la complejidad que comporta su propósito y ofrece un conjunto inicial de procesos para medir el rendimiento y el comportamiento de los tejidos, así como una manera de utilizar estos datos para dar forma a un modelo predictivo.

<p>AGRADECIMIENTOS</p>
<p>Este trabajo ha contado con el apoyo de la National Natural Science Foundation de China (NSFC, beca nº 51750110497) y por la Xi’an Jiaotong-Liverpool University (beca nº RDF-13-02-19 y RDF-17-01-54). Quisiéramos agradecer a Santoni Shanghai su generosidad, los recursos que nos ha ofrecido y el apoyo que nos ha brindado para que este proyecto fuera posible.</p>

<p>BIOGRAFÍAS</p>
<p><b>Martijn ten Bhömer</b> Xi’an Jiaotong-Liverpool University</p>

El Dr. Martijn ten Bhömer es profesor del departamento de Diseño Industrial, director del máster en Diseño Industrial y director del laboratorio de Fabricación Digital de la Universidad de Xi’an Jiaotong-Liverpool. Realizó sus estudios de doctorado en el grupo de investigación Diseño de Calidad en Interacción del Departamento de Diseño Industrial de la Universidad Tecnológica de Eindhoven. Antes de entrar en el departamento de Diseño Industrial, Martijn adquirió experiencia en el sector trabajando en empresas como Microsoft Research (Reino Unido), Deutsche Telekom (Alemania), OMsignal (Canadá) y Bambi Medical (Países Bajos). En sus trabajos de investigación analizó cómo puede la aplicación de la filosofía incorporada apuntalar el diseño y la fabricación de servicios y productos textiles inteligentes.

<p><b>Hai-Ning Liang</b> Xi’an Jiaotong-Liverpool University</p>

El Dr. Hai-Ning Liang es profesor asociado del departamento de Informática e Ingeniería de Software de la Universidad de Xi’an Jiaotong-Liverpool (XJTLU). Es subdirector del laboratorio de Suzhou de tecnologías de realidad virtual. Obtuvo el doctorado en Informática en la Universidad de Western Ontario. En sus estudios combina la interacción persona-ordenador y la visualización de información para desarrollar innovadoras interfaces de ordenador aplicables a dispositivos ponibles, de realidad aumentada/virtual y móviles.

<p><b>Difeng Yu</b> Xi’an Jiaotong-Liverpool University</p>

Difeng Yu se graduó con matrícula en Informática en la Universidad Xi’an Jiaotong-Liverpool (XJTLU) en 2018. Actualmente es investigador asociado del laboratorio de realidad virtual de la XJTLU. Sus estudios de investigación se centran en la interacción persona-ordenador. También estudia las tecnologías de aprendizaje automático.

<p><b>Yuanjin Liu</b> Xi’an Jiaotong-Liverpool University</p>

Yuanjin Liu obtuvo el título de Ingeniería Eléctrica y Automatización con matrícula en la Universidad Xi’an Jiaotong-Liverpool (XJTLU) en 2017 y el máster en Diseño Industrial con matrícula en la Universidad de Liverpool en 2019. Su tesis de máster se centró en el uso del diseño del movimiento para potenciar la respuesta emocional a productos inteligentes. Actualmente trabaja como diseñador e investigador en el ámbito de la interacción persona-ordenador.

<p><b>Yifan Zhang</b> Xi’an Jiaotong-Liverpool University</p>

Yifan Zhang obtuvo el título de Ingeniería Electrónica y Eléctrica con matrícula en la Universidad de Xi’an Jiaotong-Liverpool en 2014. Obtuvo el máster en Automatización y Control con matrícula en la Universidad de Newcastle en 2015 y el máster en Diseño Industrial en la Universidad de Liverpool en 2019. Su tesis se centró en la representación visual del comportamiento humano en el diseño de producto.

<p><b>Eva de Laat</b> <b>Carola Leegwater</b> Eva x Carola</p>

Eva x Carola es un estudio de diseño creado por Carola Leegwater y Eva de Laat. Ambas diseñadoras se especializaron en Dirección de Moda y Producción Internacional en el reputado Amsterdam Fashion Institute. Tras graduarse, Eva y Carola trabajaron en Nike, la marca de ropa deportiva, donde desarrollaron y crearon productos para competiciones de ámbito internacional como el Tour de Francia, la Copa Mundial de la FIFA y los Juegos Olímpicos. Actualmente Eva x Carola destacan en la industria de ropa deportiva por su investigación, desarrollo y creación de materiales textiles de última generación que además de ofrecer prestaciones únicas en cuanto a bienestar y sostenibilidad se personalizan en función de las necesidades de cada atleta. El dúo, que recientemente ha sido nominado a los premios Future Textiles Awards, colabora con empresas como Santoni Shanghai, Lenzing y Woolmark creando ropa de deporte innovadora que se aparta del diseño convencional y propone alternativas de futuro e inteligentes.

<p>FIGURAS Y TABLAS</p>

**Fig. 1.** Pasos que normalmente se siguen en el proceso de diseño de prendas de ropa (fotos del proyecto CRISP, Universidad Tecnológica de Eindhoven). En este proyecto en concreto se utilizó una máquina de tejido plano, a diferencia de las máquinas de tejido circular que se han utilizado en este artículo.
**Fig. 2.** Proyecto de ejemplo de prenda de ropa sin costuras diseñada por el equipo de diseño de prendas del proyecto y fabricada con máquinas de tejido circular. El sujetador de deporte combina varias texturas funcionales: 1) Estructuras abiertas para ofrecer transpirabilidad; 2) Zonas rígidas para corrección de postura; 3) Estructuras texturizadas para la circulación del aire; y 4) Zonas de puntos más apretados y más flojos para crear zonas de confort y elasti-

cidad por una parte y zonas rígidas por otra. El sujetador, por naturaleza, es una prenda extremadamente personal. Puede variar en muchos aspectos, no solo en su función, tamaño y estilo, sino también en cómo se lleva y en el apoyo que debe brindar. Imágenes y proyecto de Studio Eva x Carola.

**Fig. 3.** Ejemplos de ficheros de tramas que representan instrucciones para máquinas de tejer. Los colores de la trama de la izquierda representan los distintos materiales o superficies tal como los describe el diseñador. La trama de la derecha representa las distintas estructuras de puntos que debe hacer la máquina (cada píxel representa una puntada de la aguja).

**Fig. 4.** Punto liso (a) y los tres tipos de punto de nuestro modelo de datos: (b) punto del derecho; (c) basta; (d) malla cargada. Figuras adaptadas de (Spencer 2001).

**Fig. 5.** Puntos de malla cargada distribuidos horizontalmente en una tela: (a) punto liso; (b) basta 1 x 1; (c) basta 1 x 2; (d) basta 1 x 3. Figuras adaptadas de (Liu et al. 2016).

**Fig. 6.** Variaciones en la cobertura tubular según porcentajes.

**Fig. 7.** Aspecto de una de las estructuras tubulares (basta 1 x 3, 25% de cobertura).

**Fig. 8.** Valores RMSE y R² para el objetivo de pesoa. Las múltiples líneas de colores representan los resultados previstos a partir de la validación cruzada de una serie típica de datos de prueba. Tanto el RMSE como el R² sugieren que determinados modelos (como el de árboles potenciados y la red neuronal) se adaptan muy bien a los datos.

**Fig. 9.** Valores RMSE y R² para el objetivo de evaporación<sup>a</sup>. El algoritmo de árboles potenciados tiene un valor relativamente bajo de RMSE y alto de R².

**Fig. 10.** Valores RMSE y R² para el objetivo de elongación<sup>a</sup>. Todos los algoritmos fueron incapaces de predecir el objetivo de RMSE y de R² con exactitud. Ello se podría deber a los problemas en nuestra medición de los datos.

**Fig. 11.** Valores RMSE y R² para el objetivo de índice de energía<sup>b</sup>. El algoritmo de árboles potenciados funciona bien, visible en los valores bajos de RMSE y altos de R².

**Fig. 12.** Valores RMSE y R² para el objetivo de elongación<sup>b</sup>. El algoritmo de árboles potenciados funciona bien, visible en los valores bajos de RMSE y altos de R².

**Fig. 13.** Valores RMSE y R² para el objetivo de índice de confort<sup>b</sup>. Ciertos problemas con los modelos (sobre todo algoritmos lineales).

**Fig. 14.** Valores RMSE y R² para el objetivo de fuerza de descarga<sup>b</sup>.

**Fig. 15.** Valores RMSE y R² para el objetivo de diámetro de prenda<sup>b</sup>.

**Fig. 16.** Valores RMSE y R² para el objetivo de índice de potenciab. Es evidente a la vista de las líneas de RMSE y R² que todos los modelos tenían problemas en este caso.

**Fig. 17.** Propuesta de ventana principal del programa.

**Fig. 18.** a) Muestra la ventana de diseño de tramas. Cambiando los valores de la trama de puntos (como la estructura de puntos y el tipo de puntos), cambia también la representación visual de la trama. Los valores de la derecha muestran la predicción de los valores de las funciones. El punto b) muestra el lienzo de tramas con una forma cargada. Haciendo clic en la forma y seleccionando una trama de la biblioteca, el programa llena la forma con la trama.

**Fig. 19.** Captura de pantalla del prototipo. Desde el área de control de la izquierda el diseñador puede cambiar la proporción y la estructura del tipo de punto especial arrastrando la línea hacia la izquierda o la derecha. Durante la manipulación, los valores de la derecha mostrarán los resultados previstos. Cambiando el algoritmo en la lista desplegable se pueden probar varias predicciones. Las estadísticas dan información sobre la fiabilidad de la predicción.

<p><b>Tabla 1.</b> Variables objetivo elegidas.</p> <p><b>Tabla 2.</b> Resumen de las variables objetivo elegidas. Las variables indicadas con a fueron sometidas a pruebas en nuestro laboratorio. Las variables objetivo indicadas con b fueron sometidas a pruebas en un laboratorio externo.</p> <p><b>Tabla 3.</b> Información de las 36 muestras tejidas.</p> <p><b>Tabla 4.</b> Información de las 36 muestras ordenadas por variación.</p> <p><b>Tabla 5.</b> Resultados de las pruebas</p> <p><b>Tabla 6.</b> Resumen de los modelos de aprendizaje automático y de las técnicas de pre-procesado.</p>

**Tabla 7.** RMSE de los seis algoritmos seleccionados en la evaluación final.

**Tabla 8.** R² de los seis algoritmos seleccionados en la evaluación final. Esta tabla sugiere que el valor de elongación probado en laboratorio seguramente no es tan exacto como el valor de elongación probado externamente.

<p>REFERENCIAS</p>

Ver lista completa de referencias en la página 61.