

**АСПЕКТЫ ПРИМЕНЕНИЯ
ИНСТРУМЕНТОВ ЦИФРОВИЗАЦИИ
В ТЕКСТИЛЬНОЙ И ЛЕГКОЙ ПРОМЫШЛЕННОСТИ**

**ASPECTS OF APPLYING
DIGITALIZATION TOOLS
IN THE TEXTILE AND LIGHT INDUSTRY**

A.P. ИБАТУЛЛИНА, И.В. КРАСИНА, В.В. БРОНСКАЯ
A.R. IBATULLINA, I.V. KRASINA, V.V. BRONSKAYA

(Казанский национальный исследовательский технологический университет)

(Kazan National Research Technological University)

E-mail: twopizzas@mail.ru

В работе рассмотрены некоторые аспекты цифровизации индустрии моды и инструменты для ведения производственного процесса текстильных и швейных предприятий. В статье приведен алгоритм тренировки нейросети по распознаванию переплетений текстильного полотна и классификации изображений с целью обнаружения дефектов изделия.

The paper considers some aspects of the digitalization of the fashion industry and tools for conducting the production process of textile and clothing enterprises. The article presents an algorithm for training a neural network to recognize the weaves of a textile fabric and classify images in order to detect product defects.

Ключевые слова: цифровизация, проектирование, программное обеспечение, мониторинг, системы автоматизированного проектирования, нейросети.

Keywords: digitalization, design, software, monitoring, computer-aided design systems, neural networks.

На сегодняшний день тема цифровизации является крайне актуальной во всех областях, и отрасль текстильной и легкой промышленности не является исключением. Особенно актуальны такие цифровые разработки, как система автоматизированного проектирования (САПР) и система планирования и мониторинга производственных заказов (СПМПЗ). САПР в сочетании с системой для примерки изделий в виртуальной среде позволяет в разы сократить время на изготовление опытного образца и уменьшает число опытных образцов, необходимых для "подгонки" по фигуре человека до одной единицы. В других отраслях промышленности, например, таких как

горнодобывающая, нефтяная СПМПЗ уже активно внедряются и успешно применяются для мониторинга и контроля сроков, оптимизации временных затрат с помощью централизации всех систем производства.

Внедрение информатизации производственного процесса на предприятии легкой промышленности может рационализировать формирование плана производства на основе списка заказов или объемного плана. Распределение производственных заданий на основании реального графика работы оборудования и персонала, его доступности и производительности, а также указание и отслеживание комплектующих изделия и количества изделий в необхо-

димой для выпуска партии помогает оптимизировать временные затраты.

Применение информационных и цифровых технологий также актуально при ведении научных разработок для моделирования процессов инновационных отделочных операций текстильных изделий и модификации их свойств [1], [2].

Рассмотрим современное состояние нейросетевого моделирования в области перспективных пакетов прикладных программ для анализа и прогнозирования поведения объектов легкой промышленности [3...10].

Нейронные сети применяются с целью:

- повышения эффективности планирования и управления производством в легкой промышленности с построением функции регрессии;

- классификации изображений;
- нахождения дефектов изделия.

Общим для всех этих задач является то, что вход в сеть представляет собой некую последовательность. Эти входные данные обычно имеют переменную длину, что означает, что сеть может одинаково хорошо работать как с короткими, так и с длинными последовательностями. Что отличает различные задачи обучения последовательности, так это форма вывода сети. Здесь существует большое разнообразие методов с соответствующими формами вывода:

Для моделей авторегрессионного языка, используемых для моделирования вероятности конкретной последовательности, выходом является следующий элемент последовательности. В случае текстовой модели это символ или маркер, декодированный с помощью "Класс", "Символы" или "Токен".

Приведем алгоритм построения регрессии в условиях неопределенности.

1. Построить сеть, которая принимает входное число и использует многослойный перцептрон для создания трех отдельных векторов. Каждый вектор содержит шесть чисел, которые представляют параметры для шести отдельных гауссовских компонентов. Два из этих векторов ("среднее" и "стандартное отклонение") представляют собой среднее и стандартное отклонение. Конечный вектор ("вес") – это вектор

вероятности, который представляет, как смешать эти шесть компонентов для получения единого распределения.

2. Затем необходимо построить более крупную сеть, обучающую эту сеть параметров. Более крупная сеть берет фактические значения x и y из нашего распределения данных и вычисляет меру того, насколько вероятно данные соответствуют модели, которую представляет наша сеть параметров. Минимизируя эту отрицательную логарифмическую вероятность, мы эффективно максимизируем вероятность фактических данных, что является обычным методом обучения вероятностной модели.

4. Построить обучающую сеть.

5. Обучить модель, что соответствует одновременному максимальному увеличению вероятности того, что модель создаст каждую точку в нашем наборе данных. После обучения мы извлечем сеть параметров изнутри обученной сети.

6. Тренировка сети.

Для моделей распознавания и классификации входная последовательность используется для формирования последовательности прерывистых прогнозов для целевой последовательности, которая всегда короче входной последовательности. Примеры этого включают распознавание рукописного текста на основе данных пикселей или штрихов, при которых ввод сегментируется на отдельные символы, или транскрипция звука, в которой особенности звука сегментируются на символы или фонемы.

Приведем алгоритм классификации изображений, с целью нахождения дефектов изделия.

1. Получить данные для обучения и проверки.

2. Определить сверточную нейронную сеть, которая принимает в качестве входных данных изображения в оттенках.

3. Обучить сеть (с помощью аппарата предоставленного прикладным пакетом программ).

4. Оценить обученную сеть непосредственно на изображениях, случайно выбранных из набора для проверки. То есть выбираются изображения, для которых сеть дает самые высокие и самые низкие

предсказания энтропии. Входные данные с высокой энтропией можно истолковать как те, для которых сеть наиболее не уверена в правильном классе.

5. Получить оценки вероятности всех классов для определенного входа.

6. Проверить производительность классификации обученной сети на тестовом наборе.

Важной теоретической и прикладной задачей является многомерный анализ альтернатив нейросетевого моделирования с обоснованием их архитектуры и технологических параметров с целью принятия более обоснованных управленческих решений. Нейронные сети хорошо подходят для обучения на очень больших наборах данных, даже на тех, которые слишком велики, чтобы уместиться в памяти. Наиболее популярные алгоритмы оптимизации для обучения нейронных сетей представляют собой разновидности подхода, называемого стохастическим градиентным спуском. В этом подходе небольшие пакеты данных случайным образом выбираются из полного набора обучающих данных и используются для обновления параметров. Таким образом, нейронные сети являются примером алгоритма онлайн-обучения, что не требует, чтобы весь набор обучающих данных находился в памяти. Это контрастирует с такими методами, как алгоритм опорных векторов и случайный лес, которые обычно требуют, чтобы весь набор данных находился в памяти во время обучения.

Результат нейронной сети часто является предсказанием. Для задачи регрессии этот прогноз обычно представляет собой точечную оценку, что означает, что это одно число, представляющее значение, которое, по мнению сети, наиболее вероятно для задачи.

Для задач классификации выходом сети обычно является вектор, компоненты которого представляют вероятность каждого класса. Например, сеть, которая классифицирует изображения виды плетения, создает вектор с компонентами, сумма которых равна единице, представляя вероятности этих классов.

Для такого рода выходных векторов вероятностей мы обычно заботимся о наиболее

вероятном классе, а не о необработанных вероятностях. Чтобы определить это, мы должны знать, как классы связаны с конкретными компонентами вектора.

Есть также другие свойства, которые мы также можем вычислить из вектора вероятности, такие как верхние n вероятностей (если у нас много классов), вероятность определенного класса или мера неопределенности прогноза.

Для реализации работы моделей нейронных сетей разного вида существует специальное программное обеспечение. В качестве наиболее удобного и адаптированного для квалифицированного пользователя средства могут быть рекомендованы:

1. Statistica Neural Networks
2. Надстройка ExcelNeuralPackage
3. Пакет MatLab, Matlab Simulink
4. Пакет Wolfram Mathematica.

Нейронные сети могут быть модулем в системе управления технологическим процессом на предприятии легкой промышленности и ускорить процесс обработки большого числа данных, осуществлять мониторинг качества продукции, в перспективе в сочетании с другими средствами цифровизации, оптимизировать технологическую схему процесса.

Рассмотрим далее практические аспекты применения инструментов цифровизации в текстильной и легкой промышленности.

Полный цикл цифрового производства изделий легкой промышленности включает:

- проектирование чертежей и лекал,
- отладку лекал с помощью виртуальной примерки на аватара с заданными параметрами фигуры,
- уточнение расположения рисунка или совмещение узора ткани на частях изделия,
- цифровые технологии текстильной печати,
- цифровые технологии раскроя,
- пошив готового изделия.

Для ведения бизнеса в соответствии с требованиями Индустрии 4.0 предприятия текстильной и легкой промышленности должны обладать автоматизированным оборудованием и программным обеспечением

нием. На сегодняшний день в России существуют компании, которые ведут подобные разработки и занимаются их распространением. Лидерами на этом рынке является компания Смарт-Т в сотрудничестве с компаниями Ассоль и Веллес. Компания Ассоль зарекомендовала себя на рынке как надежный поставщик текстильного СА-Пра. Фирма Веллес является первым российским брендом промышленных швейных машин, компания также занимается обеспечением предприятий вязальным оборудованием и предлагает полностью автоматизированные производственные линии для пошива таких актуальных изделий, как медицинские маски.

Организация Смарт-Т, как официальный дистрибьютор компании Mimaki в России, занимается поставками новейшего текстильного оборудования.

Список современного оборудования для текстильного рынка включает в себя такие позиции, как принтеры для печати на футболках, УФ-принтеры, режущие плоттеры и многое другое. Так, участок печати может быть представлен широкоформатными принтерами Mimaki TS500, TS300 и Tx300 для печати на синтетическом и натуральном текстиле. Термоперенос и фиксация отпечатков на ткани может осуществляться на каландровых термопрессах TitanJet RTX34 и RTX3. Эти модели являются самым популярным оборудованием в своих сегментах.

Современный раскройный цех целесообразно оборудовать промышленными автоматическими установками, например высокопроизводительным режущим плоттером iECHO BK3 и лазерным станком PHOTONIM Pro с системой автораспознавания контуров края. Такое оборудование позволяет работать с текстильными полотнами, имеющими высокую степень осыпаемости, исключая выкальзывание нитей из срезов даже таких тканей, как шифон. Это высокотехнологичное оборудование имеет точный и достаточно широкий диапазон настраиваемой мощности для тканей с различными требованиями к осуществлению технологических процессов.

На предприятиях текстильной промышленности в силу специфики производства целесообразно внедрение технических решений в виде оборудования непрерывного цикла. Примером такого решения может служить полностью автоматизированная линия переработки текстильных отходов LAROCHE SA (лоскуты, обрезь, брак), включая готовые изделия секонд хенд (с фурнитурами и прочими нетекстильными включениями). Подобные линии как нельзя лучше отвечают целям устойчивого развития. Программное обеспечение таких поточных линий с комплектом оборудования рыхления, очистки и смешивания позволяет без участия человека обеспечить производство нетканых материалов.

Сопутствующее оборудование для контроля (фильтрационная установка, кипный пресс, замасливатель, конвейерный металлодетектор, трубный металлодетектор) позволяет максимально снизить вероятность возникновения брака.

Линии для производства нетканых материалов Airlay Flexiloft (рис. 1) представляют из себя линии полного цикла с прошивкой, термоскреплением и/или другими технологиями уплотнения для следующих областей применения: квилтинг, мебельный текстиль, ковровое покрытие, агротекстиль, термоизоляция, автомобилестроение, геотекстиль, фильтрационные текстильные материалы, гигиенические изделия и многое другое.

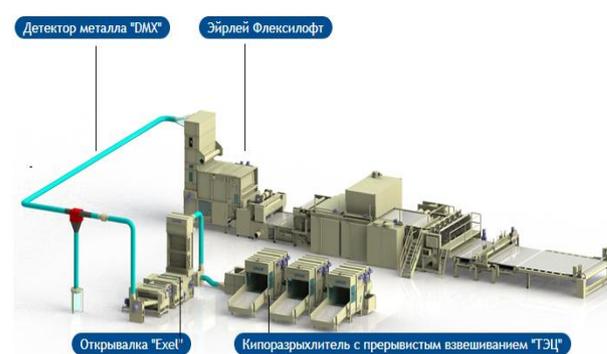


Рис. 1

Линия для производства нетканых материалов на основе смольных соединений представлена на рис. 2.

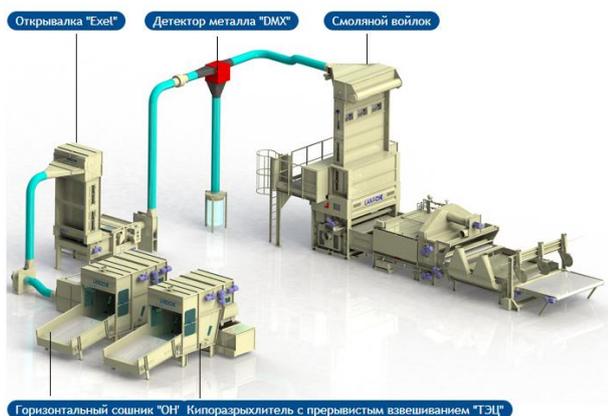


Рис. 2

Благодаря гибкости и универсальности некоторых блоков поточных линий LAROCHE выводит на рынок специальное оборудование для набивки пуха и подушек, линии протирания для последующего пряжения и создания нетканых материалов, отдельные линии для подготовки натурального волокна, линии очистки хлопка.

ВЫВОДЫ

Используя потенциал машинного обучения на всех этапах формирования изделия легкой промышленности, начиная с этапа проектирования (с учетом оптимизации затрат и тенденций устойчивого развития) и заканчивая проверкой дефектов готового изделия, появляется возможность выпуска качественного, современного, востребованного на рынке и экологически чистого продукта.

Такие примеры показывают, что информационные технологии, автоматизация и оптимизация процессов текстильной и легкой промышленности при наличии соответствующего материального обеспечения выводят производство на новый уровень.

ЛИТЕРАТУРА

1. Ibatullina A., Krasina I., Antonova M., Ilushina S., Isayeva E., Mingaliyev R. and Parsanov A. 2020 Structural and chemical changes of aramid fibers modified by low temperature plasma J. Phys.: Conf. Ser. 1588 012020.
2. Sergeeva E.A., Ibatullina A.R. and Kostina K.D. Application of plasma modification for improvement of strength characteristics of aramide fiber // Izvestiya

Vysshikh Uchebnykh Zavedenii Seriya Teknologiya Tekstil'noi Promyshlennosti. – 2016, № 1. P. 90..93.

3. Russakovsky O. et al. ImageNet large scale visual recognition challenge // Int. J. Comput. Vis. – 115, 211-252 (2015).

4. LeCun Y., Bengio Y. & Hinton G. Deep learning. Nature. – 521, 436-444 (2015).

5. Collobert R. & Weston J. A unified architecture for natural language processing: deep neural networks with multitask learning. In Proc. 25th International Conference on Machine Learning (eds McCallum, A. & Roweis, S.) 160–167 (Helsinki, Finland: ACM, 2008). <https://doi.org/10.1145/1390156.1390177>.

6. Chen L. C. et al. DeepLab: semantic image segmentation with deep convolutional nets, Atrous convolution, and fully connected CRFs. IEEE Trans. Pattern Anal. Mach. Intell. 40, 834-848 (2018).

7. Long J., Shelhamer E. & Darrell T. Fully convolutional networks for semantic segmentation. In Proc. 2015 IEEE Conference on Computer Vision and Pattern Recognition 3431–3440 (Boston, MA, USA: IEEE, 2015).

8. Rivenson Y. et al. Deep learning enhanced mobile-phone microscopy. ACS Photonics 5, 2354-2364, <https://doi.org/10.1021/acsp Photonics.8b00146> (2018).

9. Tsapaev A.A., Gumerov F.M., Mazanov S.V., Kharitonova O.S., Bronskaya V.V. Neural network model of the process of supercritical water oxidation of utilization of industrial effluent water Journal of Physics: Conference Series. – 2019, 1399(3), 033119

10. Kharitonova O.S., Bronskaya V.V., Ignashina T.V., Al-Muntaser A.A., Khairullina L.E. Modeling of absorption process using neural networks IOP Conference Series: Earth and Environmental Science. – 2019, 315(3), 032025.

REFERENCES

1. Ibatullina A., Krasina I., Antonova M., Ilushina S., Isayeva E., Mingaliyev R. and Parsanov A. 2020 Structural and chemical changes of aramid fibers modified by low temperature plasma J. Phys.: Conf. Ser. 1588 012020.
2. Sergeeva E.A., Ibatullina A.R. and Kostina K.D. Application of plasma modification for improvement of strength characteristics of aramide fiber // Izvestiya Vysshikh Uchebnykh Zavedenii Seriya Teknologiya Tekstil'noi Promyshlennosti. – 2016, № 1. P. 90..93.
3. Russakovsky O. et al. ImageNet large scale visual recognition challenge // Int. J. Comput. Vis. – 115, 211-252 (2015).
4. LeCun Y., Bengio Y. & Hinton G. Deep learning. Nature. – 521, 436-444 (2015).
5. Collobert R. & Weston J. A unified architecture for natural language processing: deep neural networks with multitask learning. In Proc. 25th International Conference on Machine Learning (eds McCallum, A. & Roweis, S.) 160–167 (Helsinki, Finland: ACM, 2008). <https://doi.org/10.1145/1390156.1390177>.
6. Chen L. C. et al. DeepLab: semantic image segmentation with deep convolutional nets, Atrous

convolution, and fully connected CRFs. *IEEE Trans. Pattern Anal. Mach. Intell.* 40, 834-848 (2018).

7. Long J., Shelhamer E. & Darrell T. Fully convolutional networks for semantic segmentation. In *Proc. 2015 IEEE Conference on Computer Vision and Pattern Recognition* 3431–3440 (Boston, MA, USA: IEEE, 2015).

8. Rivenson Y. et al. Deep learning enhanced mobile-phone microscopy. *ACS Photonics* 5, 2354-2364, <https://doi.org/10.1021/acsp Photonics.8b00146> (2018).

9. Tsapaev A.A., Gumerov F.M., Mazanov S.V., Kharitonova O.S., Bronskaya V.V. Neural network model of the process of supercritical water oxidation of

utilization of industrial effluent water *Journal of Physics: Conference Series.* – 2019, 1399(3), 033119

10. Kharitonova O.S., Bronskaya V.V., Ignashina T.V., Al-Muntaser A.A., Khairullina L.E. Modeling of absorption process using neural networks *IOP Conference Series: Earth and Environmental Science.* – 2019, 315(3), 032025.

Рекомендована кафедрой технологии натуральных, химических волокон и изделий. Поступила 08.02.22.
