

# ИДЕНТИФИКАЦИЯ НА ПРЪСТОВИ ОТПЕЧАТЪЦИ ЧРЕЗ ДИСКРЕТНА УЕЙВЛЕТ ТРАНСФОРМАЦИЯ И НЕВРОННИ МРЕЖИ С SCG ОБУЧАВАЩ АЛГОРИТЪМ

**Ивелина Балабанова**

*Технически университет - Габрово, ул. „Хаджи Димитър“ № 4, Габрово, България,  
Кореспондиращ автор: ivstoeva@abv.bg*

## FINGERPRINT IDENTIFICATION BY DISCRETE WAVELET TRANSFORM AND NEURAL NETWORKS WITH SCG LEARNING ALGORITHM

**Ivelina Balabanova**

*Technical University of Gabrovo, 4 Str. "Hadji Dimitar", Gabrovo, Bulgaria,  
\* Corresponding author: ivstoeva@abv.bg*

### Abstract

*The paper proposes a fingerprint recognition approach for user authentication and access using DIP (Digital Image Processing) and AI (Artificial Intelligence) tools. The processing procedures of biometric data doffed with the adaptation of image compression techniques - 2D Discrete Wavelet Transform (DWT), have been conducted. A dataset with features - complex of Approximation and Detail coefficients, for the personalization of 6 persons has been formed. Feed-Forward Neural Networks (FFNNs) training and verification processes with Gradient learning using Scaled Conjugate Gradient (SCG) algorithm was carried out. An assessment of biometric recognition accuracy in examining a wide range of upscaling of neurons in the hidden network layers was summarized. A complex analysis about Validation performance, Training state, Deviation between target and output network results and Concussion matrices of the network architectures with the highest and lowest established adaptability has been obtained.*

**Keywords:** fingerprint; image processing; DWT coefficients; FFNNs; gradient algorithm.

### 1. ВЪВЕДЕНИЕ

Биометричните системи се основават на използването на измерими физиологични или поведенчески характеристики, даващи възможност за надеждна автентификация на лица спрямо регламентирани нива на сигурност. В инфраструктурно отношение се разграничават "Server-based" и "Client-based" архитектури [1, 2]. Някои от най-разпространените разновидности на този род системи функционират на принципа на:

- лицево разпознаване;
- гласова идентификация;
- ирисово/ретиново сканиране, анализ на очен отпечатък;
- диагностика на електронни подписи;

- анализ на специфични геометрични особености на ръката;
- разпознаване на вени;
- верификация на пръстови отпечатъци и др.

По-специално пръстовата биометрия намира широка употреба в редица сектори като „контрол на имиграцията“, „банкови операции“, „криминалистика“, „здравеопазване“, „публичен транспорт“ [1-5]. Сред съвременните технически средства, използвани за снемане и регистрация на пръстови биометрични данни, могат да бъдат споменати „конвенционални Prism-Туре оптични сензори“, „Solid-State сензори“ и „иновативни оптични сензори, използващи дисперсията

на светлинните лъчи от вътрешната структура на отпечатъка“ [6].

В доклада е разработен подход за диагностика на лица – обект на потребителска автентификация на достъпа на основата на извлечени информативни признаци чрез DWT техники и пръстова идентификация посредством изкуствени невронни мрежи с обучение по Градиентен алгоритъм SCG.

## 2. ДЕФИНИРАНЕ НА ЗАДАЧАТА ЗА БИОМЕТРИЧНА ДИАГНОСТИКА

Настоящото изследване разглежда задачата за анализ на снети пръстови отпечатъци във формат на двумерни монохромни изображения при персонализация на достъпа на шест лица, показани на Фиг. 1. Заложено е адаптиране на двумерната Дискретна уейвлет трансформация за предварителни DIP процедури, състоящи се в извличането на входящи параметри за последващо обучение и верификация на FFNNs за разпознаване.




**Фиг. 1.** Пръстови отпечатъци на а) Person №1, б) Person №2, в) Person №3, г) Person №4, д) Person №5 и е) Person №6

Вследствие на проведени pre-processing дейности с използване на Haar, Coiflets, Biorthogonal и Symplets видове DWT беше получен комплекс от „Апроксимиращи“ и „Детайлиращи“


коэффициенти. Указаните категории характеристики са използвани за обучение на трислойни невронни структури с пряко разпространение на сигналите и обратно разпространение на грешката при задаване на „тангес-сигмоидална“ и „softmax“ функции на активация в скритите и изходните слоеве. Обучаващите процеси са FFNN моделите за пръстова идентификация са съобразени спрямо изискване за минимизация на грешката при обучение, с оглед, на което беше избран Градиентен алгоритъм Scaled Conjugate Gradient. Спецификата на прилагания обучаващ подход и типа на активационната функция в изходните слоеве регламентира интерпретирането на генерираните мрежови резултати не като числов, а като вероятностен тип.

## 3. FEED-FORWARD МРЕЖИ ЗА АВТЕНТИФИКАЦИЯ НА БАЗАТА НА ПРЪСТОВА БИОМЕТРИЯ

Основна фаза от изследването заема експерименталното определяне на подходящ диапазон на залагане количество изчислителни единици в междинните слоеве в обхвата, на който да бъде установена структура с най-добра мрежовата производителност. Първоначално бяха избрани вариации на модели за идентификация на целевите пръстови отпечатъци със значителен брой скрити неврони „300 до 500“, „500 до 1000“, но беше констатиран фактът, че това не води до съществени разлики в критериите „Точност“ и „Cross-Entropy“. В обхвата на анализирания диапазон беше достигната максимална точност около 90.00 – 95.00 %. Поради това е въведен по-нисък диапазон „5 до 250“ на задаване на изчислителни звена в междинните слоеве на FFNNs. В рамките на проведените изследвания бяха селектирани две структури с установена най-подходяща и най-ниска адаптивност на Фиг. 2. Постигнатите точности при биометрична пръстова диагностика се равняват на 100.00 % и 83.00 % за мрежи с фиксирани 10 и 200 скрити неврона.




а)




б)

Фиг. 2. Невронни мрежи при SCG обучение с най-висока а) и най-ниска ефективност б)



а)





б)



Фиг. 3. Критерий Cross-Entropy за регистрираните невронни мрежи при SCG обучение с най-висока а) и най-ниска ефективност б)

По отношение на синтезираните крайни невронни модели за идентификация е проведена методична оценка на производителността на Фиг. 3 и състоя-

нието на мрежово обучение на Фиг. 4. Регистрирани са най-добри валидиращи производителности, съответно  $6.5825e-07$  и  $1.1137$  при крайна  $68^{ma}$  и междинна  $186^{Ta}$  итерация от цялостното невронно обучение.



а)




б)


Фиг. 4. Състояние на мрежово обучение за намерените невронни архитектури при SCG обучение с най-висока а) и най-ниска ефективност б)

При двете невронни структури е наблюдавана сходна тенденция на близко поведение на индикатора Cross-Entropy за стандартните мрежови процеси „обучение“, „валидиране“ и „тестване“. Констатирано е плавно намаляване с наличие на известни пикове и спадове в изменението на Градиента, преустановени при достигане на  $68^{mi}$  и  $192^{ii}$  обучаващ цикъл. Във връзка с мрежата с най-добра ефективност при разпознаване не са из-

вършени „validation checks“, докато при втората анализирана архитектура бяха регистрирани шест проведени верификации в хода на последната итерация.



а)



б)

**Фиг. 5.** Диаграми на грешките за установените невронни мрежи при SCG обучение с най-висока а) и най-ниска ефективност б)

Преимущества на FFNN модела при задаване на 10 междинни неврона са потвърдени спрямо отчетените нива на грешките от еталоните в отделните информационни извадки за основните мрежови процеси. За разглеждания случай постигнатите количествени еквиваленти попадат в порядък „ $1.9 \times 10^{-6}$ “ за значителен дял и „ $2.42 \times 10^{-6}$ “ за сравнително малка част от приложените еталони. По различен начин е представена параметризацията по отношение на грешките при мрежата с най-ниска установена пригод-

ност, където се забелязват в пъти по-високите нива на грешките. Спрямо основният дял на обучаващите, валидиращите и тестовите информационните еталони е констатиран постигнат минимален еквивалент от едва „0.04285“.

**All Confusion Matrix**

Output Class	1	2	3	4	5	6
1	1189 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%
2	0 0.0%	1189 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%
3	0 0.0%	0 0.0%	1189 16.7%	0 0.0%	0 0.0%	0 0.0%
4	0 0.0%	0 0.0%	0 0.0%	1189 16.7%	0 0.0%	0 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1189 16.7%	0 0.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1189 16.7%

Target Class

а)

**All Confusion Matrix**

Output Class	1	2	3	4	5	6
1	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
2	581 8.1%	1189 16.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%
3	608 8.5%	0 0.0%	1188 16.7%	0 0.0%	0 0.0%	0 0.0%
4	0 0.0%	0 0.0%	1 0.0%	1189 16.7%	0 0.0%	0 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1189 16.7%	0 0.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1189 16.7%

Target Class

б)

**Фиг. 6.** Класификационни матрици за констатираните невронни архитектури при SCG обучение с най-висока а) и най-ниска ефективност б)

Разпределението на коректно и некоректно класифицираните еталони, асоциирани към състава на дефинирани категории пръстови отпечатъци, е дадено на Фиг. 6. Във връзка с FFNN модела с влошена спецификация беше установена неправилно определена принадлежност за еталони, спадащи към състава на анализирания данни за обект на автентификация Person № 1. В изпълнение на

класификационните процедури беше получено некоректно разпределение към втора и трета изходна група, спадащи към съдържанието на приложената информационна извадка.

#### 4. ЗАКЛЮЧЕНИЕ

Постигната е добра пригодност на избора обучаващ алгоритъм и фиксираните типове на активация на изчислителните единици във втори и трети структурен слой на FFNNs при манипулации с тестовите пръстови отпечатъци. Предложеният подход следва да бъде модифициран във фазата на извличане на характеристики при обработката на биометричните данни с въвеждане на Discrete Cosine Transform (DCT). По този начин ще бъде повишено количеството на входните информативни признаци, с което се цели прилагане на аналитични инструменти за по-задълбочен и детайлен анализ относно:

- възможностите за комбиниране на различни DIP техники и оценка на ефекта върху минимизацията на грешката от разпознаване;
- повишаване на достоверността на резултатите при автентификация чрез двуетапна верификация при последователно прилагане на DWT и DCT входни информационни набори с оглед на постигане на доб-

лижаващи се точности при биометрична пръстова диагностика.

*Благодарности: Изследванията в публикацията са реализирани и финансирани по Договор № 2406E/ 2024г. „Мониторинг на мрежовия трафик и достъп на информация чрез биометрична диагностика с изкуствен интелект“.*

#### ЛИТЕРАТУРА

- [1] Kumar S., Walia E. Analysis of various biometric techniques. International Journal of Computer Science and Information Technology 2011;2(4):1595-1597.
- [2] Patel A., Patel U., Suthar F. Fingerprint recognition in biometric security systems. Journal of Knowledge and Research in Computer Science and Applications 2019;1(2):44-49.
- [3] Faridah Y., Nasir H., Kushsairy A., Safie S., Khan S., Gunawan T. Fingerprint biometric system. Trends Bioinform 2016;9(2):52-58.
- [4] Azizan N., Razak W., Bakar N., Yanya N., Aziz M., Abdullah L. The study of the applications of biometrics systems: a literature review. Journal of Engineering Science and Technology 2021;1(2021):111-119.
- [5] Genevese A., Munoz E., Piuri V., Scotti F. Advanced biometric technologies: emerging scenarios and research trends. Springer 2018;1(2018):1-28.
- [6] Uchida K. Fingerprint identification. Journal of Advanced Technologies 2015;2(1):19-27.