

# **Zastosowanie sztucznej sieci neuronowej do oceny stopnia wykształcenia operatora wybranych urządzeń stosowanych w rolnictwie precyzyjnym**

*mgr inż. Karolina Trzyniec*

**Promotor:** prof. dr hab. inż. Adam Kowalewski

**Dyscyplina:** Informatyka

## **Cel i zakres pracy**

### **Problem badawczy:**

Rozwój mechanizacji rolnictwa sprawił, że praca współczesnego operatora w coraz mniejszym stopniu polega na bezpośredniej **obsłudze** maszyny rolniczej [Trzyniec 2013]. Głównym zadaniem operatora jest zazwyczaj **zarządzanie** procesami poprzez sprawną obsługę zautomatyzowanych i skomputeryzowanych urządzeń sygnalizacyjnych i sterowniczych [Trzyniec i in. 2015]. Monitorowanie pracy maszyn za pomocą odpowiednich urządzeń sygnalizacyjno – sterowniczych, współpracujących z tymi maszynami, jest jedną z możliwości zastosowań systemów nowoczesnego, precyzyjnego rolnictwa. Systemy te nie tylko umożliwiają pozycjonowanie ciągnika czy maszyny rolniczej na polu, ale przede wszystkim - wspomagają pracę operatora poprzez dokładne prowadzenie pojazdu po wyznaczonej ścieżce [Trzyniec, Kowalewski 2016].

Żeby jednak utrzymać pojazd we właściwym torze jazdy po polu, operator musi nabyć umiejętności odpowiedniego odczytywania wskazań panelu nawigacyjnego oraz prowadzenia pojazdu według tych wskazań. Dane odczytywane przez operatora z panelu nawigacyjnego dotyczą m.in. pozycji pojazdu, kierunku jazdy oraz powierzchni, na której wykonywany jest zabieg agrotechniczny. Praktyczną trudnością, z którą mogą spotkać się operatorzy ciągników współpracujących z systemami nawigacji na pasach równoległych, jest problem z utrzymaniem prostej linii jazdy, bez odchyłeń większych niż 20-30cm, szczególnie podczas jazdy po polu o nierównych granicach lub położonym na wzniesieniu [Trzyniec, Kowalewski 2016]. Tempo nabywania umiejętności pozwalających na bezbłędną jazdę w wyznaczonym torze jest różne dla każdego operatora. Obserwacja pola z kabiny ciągnika nie pozwala na rzetelną ocenę przejazdów testowych (wykonywanych podczas szkolenia operatora), a niewielki rozmiar ekranu nawigacji uniemożliwia dokładną analizę całej trajektorii ruchu. Z tego powodu trudno jest określić moment nabycia przez operatora odpowiednich umiejętności. Natomiast obiektywne wyznaczenie tego momentu pozwala także na podjęcie

decyzji, kiedy szkolenie może zostać przerwane. Wcześniejsze zakończenie szkolenia (gdy zostanie uzyskana pewność, że operator posiadał już wymagane umiejętności) może prowadzić do znacznych oszczędności czasu i środków materialnych (na przykład paliwa potrzebnego do wykonywania przejazdów szkoleniowych).

**Celem badań** było zbudowanie neuronowego modelu rozpoznającego moment nabycia przez operatora umiejętności obsługi nowoczesnej nawigacji na pasach równoległych, stosowanej w rolnictwie precyzyjnym.

Poznawcze i utylitarne uzasadnienie celu badań:

Neuronowy model rozpoznający moment wyszkolenia operatora umożliwi określenie szybkości (tempa) nabywania umiejętności zawodowych.

Dysponowanie narzędziem, pozwalającym na monitorowanie przebiegu postępów szkolenia operatorów pozwoli na zmniejszenie czasu szkolenia.

Na podstawie przedstawionego celu badań sformułowano następującą tezę rozprawy: **Moment osiągnięcia pożądanego stopnia wyszkolenia operatora może być automatycznie rozpoznawany przez odpowiednio dobraną sztuczną sieć neuronową, uczoną na podstawie danych zbieranych podczas obserwacji procesu szkolenia innych operatorów, przy wykorzystaniu kryterium określonego przez ekspertów.**

Udowodnienie postawionej tezy wymagało zrealizowania następujących etapów badań:

- przeprowadzenie szkolenia 15 potencjalnych operatorów pojazdu współpracującego z nawigacją na pasach równoległych przez osobę nadzorującą szkolenie;
- zgromadzenie danych charakteryzujących trajektorię ruchu pojazdu sterowanego przez operatora w trakcie szkolenia;
- ocenę umiejętności operatora przez osobę nadzorującą badania, według przyjętych i uzasadnionych kryteriów;
- opracowanie zbioru uczącego sztuczną sieć neuronową na podstawie wyników przeprowadzonych badań eksperymentalnych;
- określenie struktury neuronowego modelu oraz jego uczenie;
- analizę wyników uczenia opracowanych sieci neuronowych.

Pojęcie „potencjalnych operatorów” autorka zastosowała dla wyjaśnienia, iż celem eksperymentu nie było zawodowe przygotowanie każdej z osób biorących udział w eksperymencie, lecz określenie szybkości (tempa) uczenia się czynności obsługi systemu LPS (sng. *Local Positioning System*). W istocie nabycie posiadanych umiejętności oznacza, że operator przestaje być „potencjalny”, lecz jest operatorem w pełnym tego słowa znaczeniu (choć tylko w zakresie nabycia umiejętności, jakich eksperyment dotyczył).

### **Metodyka i wyniki**

W celu sprawdzenia poziomu trudności w obsłudze urządzeń sygnalizacyjno-sterowniczych posiadających system LPS (ang. *Local Positioning System*), przeprowadzono szkolenia dla piętnastu potencjalnych operatorów pojazdu współpracującego z panelem nawigacyjnym firmy Trimble, model CFX 750. Szkolenie potencjalnych operatorów urządzenia prowadził rzeczywisty trener, który śledził i rejestrował wyniki szkolenia podczas kilkudziesięciu przejazdów testowych. Na podstawie obserwacji przebiegu przejazdów, trener podejmował decyzję o przerwaniu szkolenia w momencie, kiedy podczas minimum trzech kolejnych przejazdów trajektoria ruchu była maksymalnie zbliżona do trajektorii zadanej.

Przebieg eksperymentów terenowych był następujący:

1. operator otrzymywał zadanie przejechania zadanego toru przez trenera z wyjaśnieniem sposobu utrzymania pojazdu na wyznaczonym odcinku,
2. operator uruchamiał silnik: po włączeniu biegu, jadąc z prędkością 6-7km/h, przejeżdżał zadany odcinek (obserwując wskazania położenia pojazdu na ekranie GPS),
3. parametry jazdy, tzn. chwilowe położenia pojazdu rejestrowane były w postaci zdjęć,
4. zarejestrowane chwilowe położenia pojazdu formatowane były do dalszej analizy (komputerowej) przy pomocy programu do konwersji graficzno-numerycznej,
5. skonwertowane dane w postaci liczbowej (w układzie współrzędnych  $x$  i  $y$ ) utworzyły bazę danych charakteryzującą dany przejazd.

Ponieważ wektory  $x$  obu tras mają jednakowe położenie ( $x_{iR} = x_{iZ}$ ), a trajektorie: rzeczywista i zadana różniły się położeniem wektorów  $y$ , obliczono wartość bezwzględną z różnicy wektorów:  $y_{iZ}$  i  $y_{iR}$ . Obliczenia wykonano dla wszystkich przejazdów każdego z operatorów. Każdemu położeniu pojazdu wzdłuż toru jazdy (oś  $x$ ) odpowiada różnica położenia pojazdu względem zadanego toru jazdy, wyrażona na osi  $y$ . Pary liczb  $x_n, y_n$  odpowiadały chwilowemu położeniu pojazdu.

Zmienność różnic odchyłeń od zadanego toru jazdy wyrażana została funkcją  $y=f(x)$  w postaci wielomianu. Fizyczna interpretacja wielomianu jest następująca: jeśli znane było chwilowe położenie pojazdu na torze jazdy (oś  $x$ ), to wielomian pozwala określić, jakie było odchylenie od toru jazdy. Wielomian, uzyskany (na drodze aproksymacji) na podstawie danych z jednego przejazdu, miał następującą postać:

$$y = a_{n-1}x^{n-1} + a_nx^n + \dots + a_1x^1 + a_2x^0$$

Dzięki wprowadzeniu aproksymacji wielomianowej na wejście sieci neuronowej oceniającej prawidłowość przejazdu wprowadzać można było kilka (3 lub 4) współczynników wielomianu opisującego błędy popełnione podczas tego przejazdu zamiast 234 par współrzędnych opisujących zadaną i rzeczywistą trajektorię pojazdu.

Do uczenia sieci neuronowej wprowadzano współczynniki wielomianów w układzie trójkowym, tj. współczynniki wielomianów trzech kolejno po sobie następujących przejazdów. Chodziło o to, żeby decyzję o zadowalającym stopniu wyszkolenia operatora podejmować na podstawie obserwacji **powtarzalnych** poprawnych przejazdów. Incydentalne (przypadkowe) **pojedyncze** poprawne przejazdy zdarzające się u operatorów niewystarczająco wyszkolonych nie prowadziły dzięki temu do błędnych decyzji.

Na wyjście sieci neuronowej wprowadzono binarną ocenę trzech kolejnych przejazdów. Ocena ta wynosiła 1 tylko wówczas, gdy wszystkie trzy następujące po sobie przejazdy były poprawne.

Uwzględniając analizę literatury przedmiotu stwierdzono, że do przedstawionego w pracy problemu najbardziej przydatne będą: sieć typu perceptron wielowarstwowy - MLP (ang. *Multilayer Perceptron*) oraz sieć o radialnych funkcjach bazowych – RBF (ang. *Radial Basis Function*).

Zaprojektowana sieć, wykorzystująca współczynniki wielomianu drugiego stopnia składała się z 9 neuronów dla każdego wektora warstwy wejściowej i jednego neuronu w warstwie wyjściowej. Dla sieci uczonej na podstawie współczynników wielomianu trzeciego stopnia ilość neuronów w wektorze warstwy wejściowej wynosiła 12. Liczby te (9 i 12) wynikają z ilości współczynników wielomianów  $N=2$  i  $N=3$  stopnia opisujących trzy kolejno następujące po sobie przejazdy.

Po ustaleniu liczby neuronów w warstwie wejściowej, należało określić liczbę warstw oraz liczby neuronów w warstwach ukrytych. Cel ten zrealizowano poprzez zastosowanie modułu automatycznego projektanta, będącego częścią pakietu Statistica Neural Networks StatSoft

[Szymczyk i in. 2015]. Utworzono 1000 sieci typu MLP wykorzystujących współczynniki wielomianu o stopniu  $N=2$  i 1000 sieci typu MLP wykorzystujących współczynniki wielomianu o stopniu  $N=3$ . Założono minimalną liczbę neuronów w warstwie ukrytej równą 1 i maksymalną liczbę neuronów w warstwie ukrytej równą 25.

Efektywność sztucznej sieci neuronowej w procesie zadanej klasyfikacji oceniono za pomocą wskaźników do oceny skuteczności. Za wskaźniki te przyjęto: jakość uczenia LQ, jakość walidacji VQ, jakość testowania TQ, błąd uczenia LE, błąd walidacji VE, błąd testowania TE oraz średni błąd.

Średni błąd uczenia dla sieci wykorzystującej współczynniki wielomianu drugiego stopnia nie przekroczył 2%, a dla sieci wykorzystującej współczynniki wielomianu trzeciego stopnia był znacznie wyższy i wynosił 9,6%. Średnia jakość sieci wynosiła odpowiednio 98,2% dla sieci wykorzystującej współczynniki drugiego stopnia i 90,4% dla sieci wykorzystującej współczynniki wielomianu trzeciego stopnia.

## **Wnioski**

Przedstawione w rozprawie wyniki dowodzą efektywności zastosowanego procesu klasyfikacji przejazdów opartego na metodzie wykorzystującej sztuczną sieć neuronową. Wyniki symulacji jednoznacznie potwierdzają sformułowaną w rozprawie tezę, zakładającą, że moment wyszkolenia operatora może być automatycznie rozpoznawany przez odpowiednio dobraną sztuczną sieć neuronową, uczoną na podstawie danych zbieranych podczas obserwacji procesu szkolenia operatorów, przy wykorzystaniu kryterium określonego przez ekspertów.

Z przeprowadzonych badań i analiz wynikają następujące wnioski:

1. Sztuczna sieć neuronowa może automatycznie rozpoznawać moment wystarczającego wyszkolenia operatora prowadzącego pojazd według wskazań nawigacji na pasach równoległych.
2. Sieć ta może być uczone na podstawie danych empirycznych zbieranych podczas obserwacji procesu szkolenia operatorów pod kontrolą doświadczonych instruktorów, którzy oceniają poziom wyszkolenia według przyjętego kryterium oceny.
3. Sztuczna sieć neuronowa dodana do urządzenia monitorującego szkolenie kierowcy umożliwi śledzenie postępów szkolenia i sygnalizację osiągnięcia wymaganego poziomu wyszkolenia (w niektórych przypadkach może to oznaczać skrócenie cyklu

szkolenia, a czasem może oznaczać, że mimo wykonania założonej liczby ćwiczeń operator wciąż nie posiada wymaganego poziomu umiejętności).

4. Pewna ilość kierowców nabywa pożądaną umiejętność sterowania ciągnikiem szybciej niż wymaga tego program szkolenia. Identyfikacja takich kierowców umożliwi obniżenie kosztów szkolenia (gdyż nie muszą oni kontynuować szkolenia do końca planowanego programu).
5. Zastąpienie nadzoru rzeczywistego trenera oceną przejazdów dokonywaną automatycznie za pomocą sztucznej sieci neuronowej umożliwi zastąpienie oceny subiektywnej oceną obiektywną, generowaną przez urządzenie elektroniczne, co może podnieść efektywność szkoleń.
6. Przegląd literatury wykonany przez autorkę upoważnia do stwierdzenia, że rozwiązanie postawionego problemu naukowego ma cechy oryginalności, ponieważ zaproponowana w rozprawie metoda wykorzystująca sztuczną sieć neuronową nie została dotąd zastosowana do rozwiązania problemu oceny stopnia wyszkolenia operatora.

### **Literatura:**

**Szymczyk P., Tomecka - Suchoń S. and Szymczyk M.** (2015). Neural Networks as a tool for georadar data processing. *International Journal of Applied Mathematics*, Vol. 25, No. 4, pp. 955-960.

**Trzyniec K.** (2013). Sposoby badania obciążenia psychicznego pracą. [W:] *Dokowania naukowe doktorantów – Creative Science Monografia.Creativetime*, T. 1, Kraków, 138-139.

**Trzyniec K., Juliszewski T. i Kowalewski A.** (2015). Symbole kodowania informacji na urządzeniach sygnalizacyjnych i sterowniczych ciągników i maszyn rolniczych. *Technika Rolnicza Ogrodnicza Leśna*, Nr 2, Poznań, ss. 12-15.

**Trzyniec K. and Kowalewski A.** (2016). Assessment of the degree of training of the operator of state-of- the-art signalling and control devices. *Journal of research and applications in agricultural engineering*, Nr 2, Poznań, ss. 120-122.