przemiany cholesterolu. Główną rolę wydają się odgrywać ich własności fizyczne: rozpuszczalność i lepkość, przy czym działanie hipocholesterolemiczne mają głównie włókna rozpuszczalne – gumy i pektyny.

Wpływ włókna na gospodarkę cholesterolem polega najprawdopodobniej na adsorpcji na nim kwasów żółciowych, skutkiem czego obniżeniu ulega wchłanianie cholesterolu z przewodu pokarmowego. Drugą możliwością jest hamowanie lipogenezy w wątrobie przez kwas propionowy, powstający z niestrawionego włókna w jelicie grubym w wyniku fermentacji bakteryjnej. W przypadku rozpuszczalnych form włókna możliwe są również zmiany w wydzielaniu insuliny pod wpływem koloidów o różnej lepkości. Różnice w lepkości treści przewodu pokarmowego mogą też w ostatecznym efekcie wpływać na aktywność enzymów biorących udział w syntezie cholesterolu.

Jak widać z tego krótkiego przeglądu, trudno jednoznacznie określić wpływ różnych składników dawki pokarmowej na poziom cholesterolu w tkankach. Jedną z głównych przyczyn rozbieżności wyników są najprawdopodobniej różnice w składzie pasz stosowanych w różnych doświadczeniach. Pomimo to, można stwierdzić istnienie wyraźnie zarysowanych tendencji. I tak, większość wyników wskazuje, że nienasycone kwasy tłuszczowe są hipocholesterolemiczne w porównaniu do nasyconych. Białka roślinne, w przeciwieństwie do zwierzęcych, najprawdopodobniej obniżają poziom cholesterolu. To samo wydaje się dotyczyć wolniej trawionej skrobi i rozpuszczalnych form włókna.

Trzeba też wziąć pod uwagę, że na wyniki mają wpływ czynniki nie związane z pokarmem, lepiej poznane w badaniach nad zdrowiem ludzi, prowadzonych siłą rzeczy na większą skalę. Są to czynniki genetyczne, czas trwania badań, a nawet pora roku (stwierdzono spadek poziomu cholesterolu w lecie i w zimie, a wzrost wiosną i jesienią). Z wszystkimi tymi czynnikami możemy mieć do czynienia u zwierząt doświadczalnych i gospodarskich, co może dodatkowo utrudniać interpretację wyników.

Sieci neuronowe w hodowli zwierząt?

Wilhelm Grzesiak

AR w Szczecinie

Sieci neuronowe (Neural Network) są metodą przetwarzania informacji, a ich początków należy szukać w opracowaniach neurofizjologów i pionierów bioniki. Sieć neuronowa jest specyficznym modelem ludzkiego mózgu i być może w jakimś stopniu imituje jego działanie (np. zdolność kojarzenia i uczenia się). Mózg człowieka ma objętość ok. 1400 cm^3, powierzchnię ok. 2000 cm^2 i zawiera ok. 10-20 miliardów komórek nerwowych połączonych w sieć, przy czym dla zdolności intelektualnych największe znaczenie ma warstwa kory mózgowej o grubości ok. 3 mm.

Podstawowym elementem sieci neuronowej jest element przetwarzający, zwany neuronem. W pewnej mierze jest on również modelem rzeczywistej komórki nerwowej, która odbiera bodźce ze środowiska za pośrednictwem dendrytów, analizuje je w tzw. perikarionie oraz wydaje odpowiednie dyspozycje efektorom bądź kieruje impuls do kolejnych neuronów za pośrednictwem aksonu.

Sztuczny neuron przyjmuje bodźce (sygnały wejściowe) w postaci liczb rzeczywistych, pochodzących z zewnątrz sieci lub od innego neuronu. Sygnały te są powiązane z wagami, tj. liczbami rzeczywistymi, które mogą też być ujemne, a nawet w trakcie działania sieci zmieniać swoje znaki. W neuronie obliczana jest suma ważonych wejść, czyli mnożone są sygnały wejściowe przez wagi, a następnie suma ta, reprezentująca łączne pobudzenie neuronu, jest przekształcana przez pewną ustaloną funkcję aktywacji, charakterystyczną dla danego rodzaju sieci. Obliczona wartość funkcji jest ostatecznie wartością wyjściową neuronu. W neuronach stosowane są różne funkcje aktywacji, np. funkcje progowe (funkcja jednostkowa i funkcja signum), funkcje liniowe oraz funkcje nieliniowe (np. sigmoidalna czy też tangensoidalna). Obliczona wartość jest kierowana na wyjście bądź do kolejnego neuronu, co zależy od rodzaju sieci lub jej złożoności.

Sieć neuronowa, to zbiór pojedynczych neuronów połączonych ze sobą w specyficzny sposób, w wyniku czego powstają tzw. sieci jednokierunkowe, rekurencyjne czy komórkowe. Zbiór neuronów w sieci tworzy jedną bądź kilka warstw. Na przykład sieć jednokierunkowa posiada warstwę wejściową, warstwę lub kilka warstw ukrytych (elementy sieci, których nie daje się bezpośrednio obserwować od strony wejścia i wyjścia) oraz warstwę wyjściową. W warstwie wejściowej neurony przyjmują wartości zmiennych obserwowanych na zewnątrz. Do warstwy lub warstw ukrytych wprowadzane są wartości uzyskane z neuronów warstwy wejściowej, a uzyskane w tych warstwach wartości stanowią znowu wartości wejściowe dla kolejnej warstwy ukrytej bądź dla warstwy wyjściowej. Połączenia między neuronami mogą być różne, np. jeden neuron warstwy wejściowej łączy się z jednym neuronem warstwy ukrytej lub każdy neuron wejściowy łączy się z każdym neuronem warstwy ukrytej itp. W sieci jednokierunkowej przepływ informacji jest jednokierunkowy, natomiast w sieci rekurencyjnej sygnały mogą przepływać w obu kierunkach, co daje w efekcie sprzężenia zwrotne. Charakterystycznym przykładem sieci rekurencyjnej, w której wszystkie połączenia mają charakter sprzężeń zwrotnych, jest sieć Hopfielda. Nieco inna sytuacja występuje w sieciach komórkowych, w których nie ma wyróżnionych warstw, a połączenia między neuronami mają charakter dwukierunkowy, łącząc ze sobą sąsiadujące neurony.

Aby sieć mogła spełniać postawione przed nią zadania, należy ją odpowiednio przygotować. Proces przygotowania sieci nazywany jest „uczeniem sieci" i, ogólnie rzecz ujmując, polega na określeniu wartości wag, tak aby sieć przyjęła odpowiednią własność (wielkość) dla danych wejściowych. Proces uczenia ma charakter iteracyjny, czyli wielokrotne powtó-

rzenia doprowadzają w kolejnych krokach uczących do najlepszego rozwiązania problemu postawionego przed siecią (jeżeli oczywiście problem czy obserwowane zjawisko nie jest incydentalne, np. wytypowanie prawidłowych numerów totolotka w przyszłym losowaniu).

Wyróżnić można dwa warianty uczenia sieci:

- z nauczycielem (supervised learning);
- bez nauczyciela (unsupervised learning lub hebbian learning).

W pierwszym przypadku uczenie polega na tym, że podaje się sieci przykłady poprawnego działania, czyli określone sygnały wejściowe i sygnały wyjściowe (ciąg uczący). Nauczyciel dostarcza sieci przykładów, a sieć po ich przeanalizowaniu uczy się prawidłowego działania, wychwytując np. zależności między wprowadzonymi sygnałami a sygnałem czy też sygnałami wyjściowymi. Uczenie bez nauczyciela to podawanie sieci jedynie przykładowych danych, bez wskazania oczekiwanych sygnałów wyjściowych. Sieć, jeżeli jest odpowiednio zaprojektowana, potrafi przeprowadzić rozpoznanie płynących sygnałów oraz spontanicznie je sklasyfikować. Ta reguła, historycznie rzecz biorąc, jest pierwszą regułą uczenia elementu przetwarzającego sieci neuronowej i po raz pierwszy sformułował ją psycholog Donald Hebb. Regułę swą oparł na zjawisku tworzenia się nabytych odruchów warunkowych u ludzi i zwierząt. Zasada uczenia w tym schemacie polega na tym, że waga *i*-tego wejścia *m*-tego neuronu wzrasta podczas prezentacji *j*-tego wektora wejściowego proporcjonalnie do iloczynu *i*-tej składowej sygnału wejściowego docierającego do rozważanego połączenia i sygnału wyjściowego danego neuronu. Wzmocnieniu ulegają te wagi, które są aktywne w sytuacji, gdy ich neuron jest pobudzony. Stąd wynika, że sieć jest autoasocjacyjna, co oznacza, że jeśli pewien wzór pobudzeń sygnalizowany jest przez pewne *m*-te wyjście sieci, to w miarę upływu czasu ta sygnalizacja staje się coraz bardziej wyraźna. Sieć uczy się w ten sposób rozróżniać nadchodzące do niej bodźce i grupować je w pewne kategorie, gdyż neuron wytrenowany w rozpoznawaniu pewnego sygnału będzie także zdolny do rozpoznawania sygnałów do niego podobnych.

Sieć ucząca się bez nauczyciela, choć osiąga dobre wyniki, nie daje zupełnej pewności, gdyż dość istotnie zależy od początkowych, przypadkowo wybranych wartości wag. Ponadto wartości wag przez cały czas są zwiększane. Czasami dobrym antidotum na tę niepewność jest zastosowanie większej liczby neuronów niż liczba planowanych do rozpoznania kategorii. Można też różnymi sposobami ograniczać wzrost wektora wag, modyfikując tę metodę.

Uczenie pojedynczego neuronu z nauczycielem można wyobrazić sobie w ten sposób, że dobiera się wagi, aby opisana zależność między wielkościami wejściowymi (x_1, x_2,...x_n) oraz wielkością wyjściową (W) była zbliżona do rzeczywistej. Wielkość wyjściowa otrzymywana w sieci (Y) zależy od parametrów w_1, w_2,...w_n oraz funkcji aktywacji i można ją przedstawić jako:

$$Y = f(w_1, w_2, \ldots w_n)$$

Natomiast błąd (E), będący miernikiem jakości sieci, określany jest jako:

$$E = (W - Y)^2$$

Uczenie jest więc procesem, w wyniku którego dobierany jest taki zestaw wag, aby funkcja błędu była najmniejsza. Początkowe wagi dobierane są losowo. Obliczany jest tzw. gradient funkcji błędu w punkcie odpowiadającym aktualnym wartościom wag. Następnie wyznaczony przeciwny wektor do gradientu funkcji błędu przemnażany jest przez pewną wielkość, nazywaną współczynnikiem uczenia. Obliczona w ten sposób poprawka służy do zmodyfikowania wartości wag i rozpoczyna się kolejny proces (krok – epoka) uczenia z nowym, zmienionym zestawem wag. Gdy współczynnik uczenia będzie zbyt mały, uczenie rozciągnie się w czasie, natomiast przy zbyt dużym współczynniku uczenia poprawki mogą się okazać za duże i wartości wag oscylować będą wokół wartości optymalnych. Wynika stąd wniosek, że niezwykle istotnym elementem jest właściwy dobór współczynnika uczenia. Istnieje pewne niebezpieczeństwo, że algorytm działania sieci zatrzyma się w tzw. minimum lokalnym funkcji błędu, co spowoduje, iż model nie będzie posiadał właściwości uogólniających, czyli nie będzie zdolny do generowania prawidłowej odpowiedzi dla danych wejściowych, które w pierwotnym (uczącym) zestawie się nie pojawiły. Istnieją jednak pewne sposoby przeciwdziałania zatrzymaniu się funkcji błędu w minimum lokalnym.

Sieć neuronowa dobrze generalizuje, jeżeli odpowiedzi przez nią udzielane dla zestawu danych testowych są prawidłowe lub mieszczą się w granicach ustalonego błędu, przy czym dane testowe muszą pochodzić z tej samej populacji co dane wykorzystywane do uczenia sieci, ale różne od nich. Dobrą generalizację zapewnia odpowiednia długość i jakość

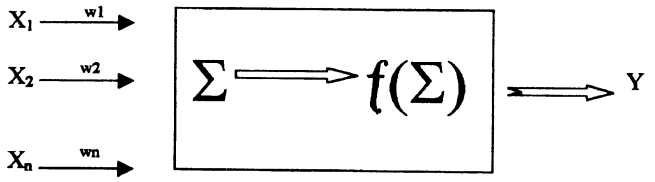

Gdzie: $X_1, X_2, \ldots X_n$ - są to sygnały wejściowe

$w_1, w_2, \ldots w_n$ - są to odpowiednie wagi

Σ - jest to suma ważonych wejść - $w_i \bullet x_i$

$f(\Sigma)$ - jest to określona funkcja aktywacji

Y - sygnał wyjściowy

Rys. 1. Schemat sztucznego neuronu

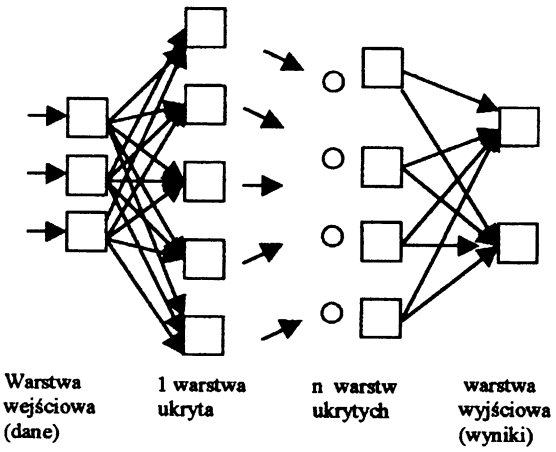

Rys. 2. Przykładowe schematy sieci neuronowych (kwadratami oznaczono neurony; strzałki wskazują na występujące połączenia; kropki imitują kolejne warstwy ukryte, już bez zaznaczania połączeń)

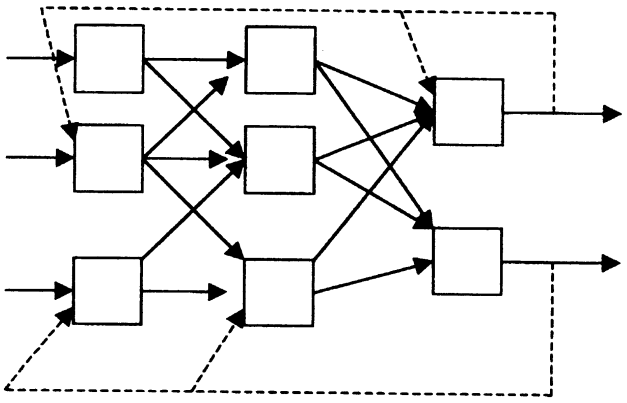

Rys. 3. Przykład sieci rekurencyjnej (linią przerywaną zaznaczono połączenia będące sprzężeniem zwrotnym)

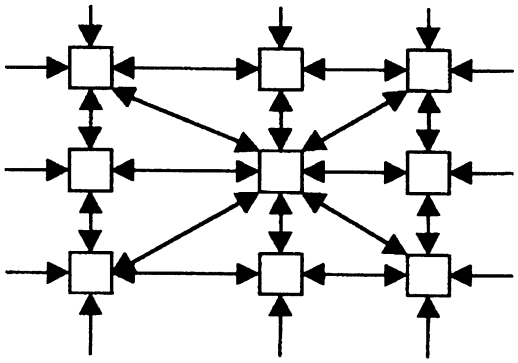

Rys. 4. Przykład sieci komórkowej

ciągu uczącego, odpowiednia architektura sieci oraz niewątpliwie złożoność problemu, z jakim mamy do czynienia. W praktyce często wpływ mamy tylko na odpowiedni dobór ciągu uczącego.

Innym istotnym elementem prawidłowo skonstruowanej sieci są jej zdolności do aproksymacji, czyli obliczania prawidłowej wartości dla danych wejściowych wchodzących w skład zestawu uczącego. Niskie błędy, zarówno dla zestawu uczącego jak i dla zestawu testowego, są wyznacznikiem właściwie dobranej struktury sieci oraz dobrze przeprowadzonego procesu uczenia sieci.

Sieci neuronowe posiadają cenne zalety. Wyjścia neuronów danej warstwy zależą jedynie od wyjść neuronów warstwy poprzedniej, czyli neurony każdej warstwy są niezależne, dzięki czemu możliwe jest zastosowanie równoległego przetwarzania. Warstwy sieci mogą wykonywać obliczenia jednocześnie, przekazując co pewien czas ich wyniki w głąb sieci. Przetwarzanie informacji odbywa się potokowo. Odpowiedź na sygnał wyjściowy pojawia się na wyjściu sieci po pewnej liczbie przetworzeń. Liczba tych przetworzeń jest równa ilości warstw sieci. Sieć przetwarza jednocześnie pewną ilość kolejnych wymuszeń, po jednym w każdej warstwie, przez co możliwe jest wykonywanie obliczeń z prędkością równą prędkości przekazywania informacji między warstwami sieci neuronowej. W związku z tym, szybkość pracy sieci neuronowych może docelowo miliony razy przewyższać szybkość aktualnie eksploatowanych komputerów. Ponadto sieci nie trzeba programować. Metody uczenia i samouczenia sieci pozwalają uzyskać ich celowe i skuteczne działanie nawet w sytuacji, kiedy twórca sieci nie zna algorytmu, według którego można rozwiązać postawione zadanie.

Zastosowania sieci neuronowych w większości przypadków dotyczą zagadnień rozpoznawania, zlokalizowanych głównie w dziedzinach technicznych bądź ekonomicznych. Szczególnie cenne właściwości sieci wykorzystywane są do predykcji, czyli przewidywania wyników na podstawie danych wejściowych. Predykcja ma obecnie duże zastosowanie w ekonomice, np. do przewidywania zdolności kredytowej czy też różnych prognoz ekonomicznych. Sieci wykorzystywane są także do klasyfikacji i rozpoznawania podmiotów gospodarczych. Sieci neuronowe sprawdzają się także w poszukiwaniu optymalnych rozwiązań gospodarczych, są znakomitym narzędziem analizy i kojarzenia danych. Ich wykorzystań jest wiele.

W dostępnej literaturze nie znaleziono przykładu wykorzystania sieci neuronowych w rozwiązywaniu problemów istniejących w chowie i hodowli zwierząt. Tymczasem sieci neuronowe mogłyby być wykorzystane np. w różnych problemach regresyjnych czy też do eksploracji danych. Przy problemach regresyjnych skonstruowany model powinien odzwierciedlać związki istniejące pomiędzy zestawem zmiennych wejściowych objaśniających a zestawem zmiennych wyjściowych objaśnianych. Analizując pewną zmienną zależną, np. wydajność rzeźną osobnika, bierzemy pod uwagę szereg zmiennych objaśniających, zarówno jakościowych jak i ilościowych, m.in. genotyp osobnika, genotyp rodziców, wiek, czynniki środowiska (np. żywienie, sposób utrzymania zwierząt), parametry zoometryczne i wiele innych zmiennych. Sieć neuronowa, odpowiednio przygotowana i wyuczona, dokona rozpoznania zależności, jeżeli takie występują, pomiędzy wydajnością rzeźną a zmiennymi objaśniającymi. Skonstruowany model można wykorzystać uruchamiając go dla zbioru danych zebranych, np. po pewnym czasie można wybrać osobnika o określonych cechach w celu oznaczenia jego wydajności rzeźnej, ewentualnie oszacować wydajność hipotetycznego osobnika o przeciętnych wartościach zmiennych objaśniających itp. Sieci neuronowe mogłyby być wykorzystane także przy ocenie surowców pochodzenia zwierzęcego. Można przeanalizować różne wpływy na wartość (cenę) produktu zwierzęcego w zależności od szeregu uwzględnionych cech.

Innym rodzajem zastosowania sieci neuronowych w hodowli zwierząt mogłaby być klasyfikacja wzorcowa bądź bezwzorcowa. W klasyfikacji bezwzorcowej nie znamy wzorców klas. Analiza badanej zbiorowości za pośrednictwem sieci neuronowej umożliwia podział na pewną liczbę klas zawierających określone obiekty badawcze. Jedną z sieci realizujących klasyfikację bezwzorcową jest sieć Kohonena. Składa się ona z dwóch warstw: wejściowej – z liczbą neuronów zależną od struktury zbioru danych oraz wyjściowej – z liczbą neuronów określoną przez użytkownika. Uczenie sieci odbywa się w tym przypadku bez nauczyciela. Wielokrotnie powtarzana procedura uczenia doprowadza do powstania modelu spełniającego zadania mapy topologicznej. Im bardziej dwa obiekty będą do siebie podobne, tym bliżej siebie będą się znajdować odpowiadające im neurony. Ten rodzaj sieci może zostać wykorzystany do grupowania w klasy czy kategorie, do których można później zakwalifikować nowe nieznane obiekty charakteryzujące się określonymi własnościami.

W klasyfikacji wzorcowej badane zjawisko można przypisać do jednej z klas, przy czym klasy są znane przed rozpoczęciem realizacji zadania. Na wejściu sieci neuronowej należy podać wartości zmiennych opisujących badane zjawisko, zaś na wyjściu sieci należy oczekiwać przypisania danego zjawiska do określonej klasy. Załóżmy, że analizujemy podatność krów na mastitis. Na wyjściu sieci oczekujemy zakwalifikowania osobnika do klasy „podatne" lub „niepodatne" na mastitis. Na wejściu wprowadzamy szereg danych, które mogą pomóc w określeniu tej podatności, np. genotyp osobnika, wydajność mleka, zawartość składników w mleku, wiek, przebyte inne schorzenia oraz szereg innych możliwych do określenia czynników środowiska. Prawidłowo skonstruowana sieć powinna przydzielić krowy do jednej z klas.

Zagadnienie wykorzystania sieci neuronowych w chowie i hodowli zwierząt zostało zaledwie naszkicowane. Warto sięgnąć po przedstawione poniżej tytuły książek oraz skorzystać z bogatej oferty internetowej. Ponadto trzeba pamiętać, że wyrafinowana metoda, jaką są sieci neuronowe, nie zawsze musi spełniać pokładane w niej nadzieje oraz, że nie zawsze do rozwiązania problemu sieci takie są niezbędne. Czasami do rozwiązania można dojść klasycznymi metodami. Niemniej jednak jest to sposób warty polecenia i wypróbowania.

Literatura: 1. Korbicz J., Obuchowicz A., Ucinski D.: Sztuczne sieci neuronowe. Podstawy i zastosowania. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994; **2. Ossowski S.**: Sieci neuronowe. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 1994; **3. Rymarczyk M.**: Decyzje symulacyjne. Sieci neuronowe. Wydawnictwo Wyższej Szkoły Bankowej, Poznań 1997; **4. Tadeusiewicz R.**: Sieci neuronowe. Akademicka Oficyna Wydawnicza RM, Warszawa 1993; **5. Tadeusiewicz R.**: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998; **6. Żurada J., Barski M., Jędruch W.**: Sztuczne sieci neuronowe. Podstawy teorii i zastosowania. Wydawnictwo Naukowe PWN, Warszawa 1996.

Stadnina koni czystej krwi arabskiej w Białce

Marian Budzyński, Andrzej Guziuk, Jarosław Kamieniak, Marek Sapuła

Białka k. Krasnegostawu, znana dotychczas jako wyróżniający się ośrodek hodowli zarodowej koni małopolskich poprzez stado ogierów, od roku 1982 kojarzona jest także ze stadniną koni arabskich czystej krwi.

Duże zainteresowanie kupców zagranicznych polskimi końmi arabskimi oraz uzyskiwane za nie wysokie ceny były podstawowym czynnikiem, który wpłynął na podjęcie przez Wydział Hodowli Koni (za akceptacją Ministerstwa Rolnictwa) decyzji o zorganizowaniu czwartej stadniny koni czystej krwi arabskiej. Dodatkowym czynnikiem, przemawiającym za potrzebą stworzenia nowej stadniny, była konieczność zmniejszenia ryzyka nadmiernego spokrewnienia stada oraz zapewnienie hodowli arabskiej możliwości, w miarę swobodnych, kombinacji doboru par do kojarzeń. Za umiejscowieniem jej w Białce, obok istniejącego tam stada ogierów, zadecydowały z jednej strony korzystne warunki klimatyczne, sprzyjające tego typu działalności, oraz bogata baza paszowa, z drugiej zaś – dotychczasowe niepełne wykorzystanie znajdujących się w Białce budynków, urządzeń zootechnicznych oraz wyspecjalizowanej załogi. Szczególne zasługi dla powołania nowej stadniny mieli niewątpliwie: ówczesny naczelnik Wydziału Hodowli Koni – Adam Sosnowski, jego współpracownicy – Izabela Zawadzka i Jerzy Budny oraz ówczesny dyrektor PSO – Kazimierz Guziuk, a następnie inż. Andrzej Guziuk – obecny dyrektor.

Swoją działalność stadnina koni arabskich w Białce rozpoczęła w roku 1982, opierając się na materiale zarodowym sprowadzonym z już istniejących stadnin arabskich. Łącznie sprowadzono 29 klaczy stadnych, w tym najwięcej z Michałowa – 12, Janowa Podlaskiego – 10, a najmniej z Kurozwęk – 7. Klacze te reprezentowały 11 rodzin żeńskich, założonych przez oryginalne klacze arabskie importowane do Europy (Ukrainka – 10 klaczy; Gazella i Sahara po 3 klacze; Bent-El-Arab, Milordka, Rodania, Scherife, Wołoszka – po 2 klacze; Mlecha, Szamrajówka, Szweykowska – po 1 klaczy), oraz 5 rodów męskich, założonych przez oryginalne ogiery arabskie (Kuhailan Haifi – 16 sztuk; Ibrahim – 5 szt.; Ilderim – 4 szt.; Bairactar – 3 szt.; Saklawi I – 1 szt.).

W czasie ostatnich lat struktura rodowodowa aktualnego stada zarodowego w Białce uległa pewnym modyfikacjom. Oprócz stosowanego doboru, preferującego określone genotypy, wpłynęło na to między innymi poszerzenie białeckiej hodowli o klacze przekazane do Białki po likwidacji stadniny w Kurozwękach. Obecnie klacze czystej krwi arabskiej w Białce reprezentują 9 linii żeńskich (linie klaczy: Gazella – 5 szt.; Milordka – 5 szt.; Mlecha – 4 szt.; Rodania – 3 szt.; Sahara – 7 szt.; Scherife – 5 szt.; Szamrajówka – 6 szt.; Ukrainka – 6 szt.; Wołoszka – 3 szt.), oraz 6 rodów męskich (rody ogierów: Ibrahim – 11 szt.; Ilderim – 3 szt.; Krzyżyk – 4 szt.; Kuhailan Afas – 7 szt.; Kuhailan Haifi – 4 szt.; Saklawi I – 14 szt.), założonych przez oryginalne konie czystej krwi arabskiej importowane do Europy.

Od roku 1982 do 2000 w białeckiej hodowli użyto ogółem 27 ogierów. Wymagała tego duża różnorodność posiadanego stada zarodowego, obligująca hodowców do szczególnie umiejętnego doboru. Pomimo znacznej liczby reproduktorów użytych do kojarzeń, w początkowym okresie Białka nie mogła dochować się wybitnego potomstwa. Wynikało to przede wszystkim z faktu, iż najlepsze ogiery czołowe znajdowały się w wiodących dotychczas stadninach arabskich, to jest Janowie Podlaskim i Michałowie. Białce natomiast przypadły ogiery mniej cenne, a często jeszcze nie sprawdzone w hodowli. Jednak konsekwentna praca hodowlana, oparta na ostrej i ściśle ukierunkowanej selekcji, zaczęła wreszcie przynosić efekty. Dowodem tego są osiągane przez „białeckie araby" wyróżnienia na pokazach hodowlanych oraz w czasie startów na torach wyścigowych.