



Sztuczne sieci neuronowe

Krzysztof A. Cyran
POLITECHNIKA ŚLĄSKA
Instytut Informatyki, p. 311

Wykład 8



PLAN:

**- Zastosowanie sieci neuronowych do klasyfikacji
statystycznej:**

statystyczny model klasyfikacji

aproksymacja a' posteriori w sieciach MLP

probabilistyczne sieci neuronowe

Klasyfikacja statyczna

- Wyniki klasyfikacji w krokach poprzednich nie wpływają na klasyfikację w chwili bieżącej
- Przykładem jest klasyfikacja dokonywana przez WYTRENOWANĄ sieć neuronową

Klasyfikacja statystyczna - motywacja

- Klasyfikowane wektory cech są obarczone zakłóceniami powstałymi w różnego rodzaju przetwarzaniu wstępnym
- Najczęściej zakłócenia są złożeniami niezależnych zakłóceń elementarnych, zatem wynikowe zakłócenia mają normalny rozkład gęstości
- Rezultatem jest częściowe nakładanie się w przestrzeni cech regionów należących do poszczególnych klas: klasyfikacja bezbłędna jest niemożliwym do spełnienia ideałem

Klasyfikacja statystyczna – losowa klasa abstrakcji

- Wyeliminowanie determinizmu klasyfikacji daje podstawy do wprowadzenia pojęcia losowej klasy abstrakcji
- Losowa klasa abstrakcji wyznaczana jest poprzez funkcję $p(\mathbf{x} | C_k)$ określającą gęstość prawdopodobieństwa przynależności wektora \mathbf{x} do klasy C_k

Klasyfikacja statystyczna - cele

- Ponieważ dla wielu k może zachodzić jednocześnie: $p(\mathbf{x} | C_k) > 0$, zatem wiele wektorów cech nie może być zakwalifikowanych jednoznacznie do jednej tylko klasy
- Dlatego celem klasyfikacji statystycznej jest klasyfikacja, której odpowiada najmniejsze prawdopodobieństwo nieprawidłowej decyzji (uwzględniając również koszty błędnych decyzji w postaci dodatkowych wag).

Klasyfikacja statystyczna - oznaczenia

- $p(\mathbf{x} | C_k)$ – rozkład określający losowe klasy abstrakcji
- $P(C_k)$ – prawdopodobieństwo a’piori klasy C_k
- $p(\mathbf{x})$ – rozkład prawdopodobieństwa wektora cech \mathbf{x}
- $P(C_k | \mathbf{x})$ – prawdopodobieństwo a’posteriori przynależności do klasy C_k po zaobserwowaniu wektora cech \mathbf{x}

Reguła Bayes'a

- Prawdopodobieństwo koniunkcji zdarzeń zależnych (pierwsza postać):

$$P(C_k, \mathbf{x}) = P(C_k | \mathbf{x})p(\mathbf{x})$$

- Prawdopodobieństwo koniunkcji zdarzeń zależnych (druga postać):

$$P(C_k, \mathbf{x}) = p(\mathbf{x} | C_k)P(C_k)$$

- Wniosek (reguła Bayes'a):

$$P(C_k | \mathbf{x}) = \frac{p(\mathbf{x} | C_k)P(C_k)}{p(\mathbf{x})}$$

Mianownik we wzorze Bayes'a jest niezależny od klasy

- Ponieważ prawdopodobieństwo zdarzeń niezależnych wyraża się wzorem:

$$p(\mathbf{x}) = \sum_k P(C_k, \mathbf{x}) = \sum_k p(\mathbf{x} | C_k) P(C_k)$$

- Zatem mianownik wzoru Bayes'a pełni tylko rolę normalizującą, by prawdopodobieństwa a' posteriori sumowały się do jedności:

$$\sum_k P(C_k | \mathbf{x}) = 1$$

Problem określenia reguły klasyfikacji w modelu z niepewnością losową

- Określenie reguły decyzyjnej jest w ogólności zależne od celu klasyfikacji
- Najczęściej przyjmuje się minimalizację strat średnich wynikłych z błędnego zakwalifikowania
- Czasami jednak minimalizować można straty maksymalne, minimalne lub najbardziej prawdopodobne

Cel: minimalizacja strat średnich

Średnia strata wynika z sytuacji, iż wektor cech \mathbf{x} został zakwalifikowany do klasy C_j , oznaczana jako $r_j(\mathbf{x})$, jest dana wyrażeniem:

$$r_j(\mathbf{x}) = \sum_{k=1}^K L_{kj} P(C_k | \mathbf{x})$$

gdzie: L_{kj} oznacza stratę powstałą z zakwalifikowania do klasy C_j obrazu faktycznie należącego do klasy abstrakcji C_k .

Cel: minimalizacja strat średnich (cd.)

Stosując wzór Bayes'a otrzymujemy:

$$r_j(\mathbf{x}) = \frac{1}{p(\mathbf{x})} \sum_{k=1}^K L_{kj} p(\mathbf{x}|C_k) P(C_k)$$

Założenie: straty ze wszystkich błędnych decyzji są sobie równe

- Wówczas funkcję strat L_{kj} można przedstawić jako:

$$L_{kj} = 1 - \delta_{kj}$$

- Gdzie:

$$\delta_{kj} = \begin{cases} 0 & \Leftarrow k \neq j \\ 1 & \Leftarrow k = j \end{cases}$$

Straty średnie (cd.)

- Podstawiając wzór na L_{kj} do wzoru na $r_j(\mathbf{x})$ dostajemy:

$$r_j(\mathbf{x}) = \frac{1}{p(\mathbf{x})} \left(\sum_{k=1}^K p(\mathbf{x}|C_k)P(C_k) - \sum_{k=1}^K \delta_{kj} p(\mathbf{x}|C_k)P(C_k) \right)$$

- Uwzględnienie wzoru na prawdopodobieństwo całkowite oraz faktu, że δ_{kj} jest różne od zera tylko dla $k = j$, prowadzi do:

$$r_j(\mathbf{x}) = 1 - \frac{1}{p(\mathbf{x})} p(\mathbf{x}|C_j)P(C_j)$$

Wzór końcowy na straty średnie

- Stosując jeszcze raz prawo Bayes'a otrzymujemy ostatecznie:

$$r_j(\mathbf{x}) = 1 - P(C_j | \mathbf{x})$$

Klasyfikacja w modelu z niepewnością losową- podsumowanie

$$r_j(\mathbf{x}) = 1 - P(C_j | \mathbf{x})$$

• r_j - funkcja strat średnich powstałych przy zaklasyfikowaniu wektora cech \mathbf{x} jako należącego do klasy abstrakcji C_j

$$\delta(\mathbf{x}) = C_k \Leftrightarrow \forall_{j \neq k} P(C_k | \mathbf{x}) > P(C_j | \mathbf{x})$$

Reguła decyzyjna: wektor cech \mathbf{x} powinien być zaklasyfikowany do tej klasy abstrakcji C_k , dla której prawdopodobieństwo a' posteriori $P(C_k | \mathbf{x})$ jest największe

Kryterium odrzucenia

- Ponadto w modelu z niepewnością losową można zdefiniować tzw. kryterium odrzucenia:

$$\max_k P(C_k | \mathbf{x}) \begin{cases} \geq \theta & \Rightarrow \text{sklasyfikuj } \mathbf{x} \\ < \theta & \Rightarrow \text{odrzuć } \mathbf{x} \end{cases}$$

Podstawowy problem klasyfikacji statystycznej a SN

- Ponieważ reguła decyzyjna opiera się na porównaniu prawdopodobieństw a posteriori przynależności wektorów cech do klas, zatem aby ją stosować należy znać te prawdopodobieństwa
- Jak zostanie pokazane za chwilę, właściwie nauczone sieci neuronowe potrafią aproksymować te prawdopodobieństwa z wzorców uczących.

Sieci neuronowe w klasyfikacji statystycznej - założenia

- Niech klasyfikator neuronowy uczony jest dużą liczbą przykładów uczących w postaci par (\mathbf{x}, C_j) gdzie \mathbf{x} jest wektorem wejściowym (wektorem cech) a C_j prawidłową klasą abstrakcji odpowiadającą temu wektorowi. Indeks $j = 1, \dots, K$, odpowiada numerowi klasy abstrakcji, a K jest ilością klas do rozpoznania.
- Niech pary (\mathbf{x}, C_j) mają rozkład prawdopodobieństw $p(\mathbf{x}, C_j)$
- Niech $y_k(\mathbf{x})$ będzie wartością pojawiającą się na k -tym neuronie wyjściowym. Oczywiście zachodzi również:
 $k = 1, \dots, K$.

Sieci neuronowe w klasyfikacji statystycznej - założenia (cd.)

- Wymagane odpowiedzi sieci oznaczane przez T_{kj} spełniają zależność:

$$T_{kj} = \begin{cases} 1 & \Leftrightarrow & k = j \\ 0 & \Leftrightarrow & k \neq j \end{cases}$$

Sieci neuronowe w klasyfikacji statystycznej – problem uczenia

- Uczenie jest minimalizacją sumy funkcjonału błędu średniokwadratowego liczonej po wszystkich klasach i wszystkich wektorach \mathbf{x} proporcjonalnie do ich rozkładu prawdopodobieństw. Jest zatem minimalizacją wyrażenia E danego wzorem:

$$E = \int_{\mathbf{x}} \left(\sum_j p(\mathbf{x}, C_j) \sum_k (T_{kj} - y_k(\mathbf{x}))^2 \right) d\mathbf{x}$$

Sieci neuronowe w klasyfikacji statystycznej – uczenie (cd.)

- Przedstawmy funkcję błędu E jako:

$$E = \int_{\mathbf{x}} \left(\sum_k \left(\sum_j p(\mathbf{x}, C_j) (T_{kj} - y_k(\mathbf{x}))^2 \right) \right) d\mathbf{x} = \int_{\mathbf{x}} \left(\sum_k E_{\mathbf{x}k} \right) d\mathbf{x}$$

- Gdzie:

$$E_{\mathbf{x}k} = \sum_j p(\mathbf{x}, C_j) (T_{kj} - y_k(\mathbf{x}))^2$$

Sieci neuronowe w klasyfikacji statystycznej – uczenie (cd.)

- Ponieważ E_{xk} jest dodatnie dla dowolnego \mathbf{x} oraz k , zatem minimalizując go minimalizuje się również E .
- Rozdzielając wyrażenie na E_{xk} na dwie części dla: $j = k$ oraz $j \neq k$ dostajemy:

$$E_{xk} = p(\mathbf{x}, C_k)(1 - y_k(\mathbf{x}))^2 + \sum_{j \neq k} p(\mathbf{x}, C_j)y_k^2(\mathbf{x})$$

Sieci neuronowe w klasyfikacji statystycznej – uczenie (cd.)

- Kolejno przekształcamy to wyrażenie:

$$E_{\mathbf{x}k} = p(\mathbf{x}, C_k)(1 - 2y_k(\mathbf{x}) + y_k^2(\mathbf{x})) + (p(\mathbf{x}) - p(\mathbf{x}, C_k))y_k^2(\mathbf{x})$$

$$E_{\mathbf{x}k} = p(\mathbf{x}, C_k) - 2p(\mathbf{x}, C_k)y_k(\mathbf{x}) + p(\mathbf{x})y_k^2(\mathbf{x})$$

$$E_{\mathbf{x}k} = p(\mathbf{x})(p(C_k|\mathbf{x}) - 2p(C_k|\mathbf{x})y_k(\mathbf{x}) + y_k^2(\mathbf{x}))$$

$$E_{\mathbf{x}k} = p(\mathbf{x})p(C_k|\mathbf{x}) + p(\mathbf{x})(-p^2(C_k|\mathbf{x}) + p^2(C_k|\mathbf{x}) - 2p(C_k|\mathbf{x})y_k(\mathbf{x}) + y_k^2(\mathbf{x}))$$

Sieci neuronowe w klasyfikacji statystycznej – uczenie (cd.)

- Otrzymujemy ostatecznie:

$$E_{xk} = p(\mathbf{x})p(C_k|\mathbf{x})(1 - p(C_k|\mathbf{x})) + p(\mathbf{x})(p(C_k|\mathbf{x}) - y_k(\mathbf{x}))^2$$

- Widać, że E_{xk} jest minimalizowane gdy:

$$y_k(\mathbf{x}) = p(C_k|\mathbf{x})$$

SSN przybliżają na wyjściach prawdopodobieństwa a' posteriori

SSN generuje na wyjściu y_k dla wektora wejściowego \mathbf{x} błąd $E_{\mathbf{x}k}$ dany przez:

$$E_{\mathbf{x}k} = p(\mathbf{x})p(C_k|\mathbf{x})(1 - p(C_k|\mathbf{x})) + p(\mathbf{x})(p(C_k|\mathbf{x}) - y_k(\mathbf{x}))^2$$

Ponieważ pierwszy składnik sumy nie zależy od y_k , błąd jest minimalizowany gdy:

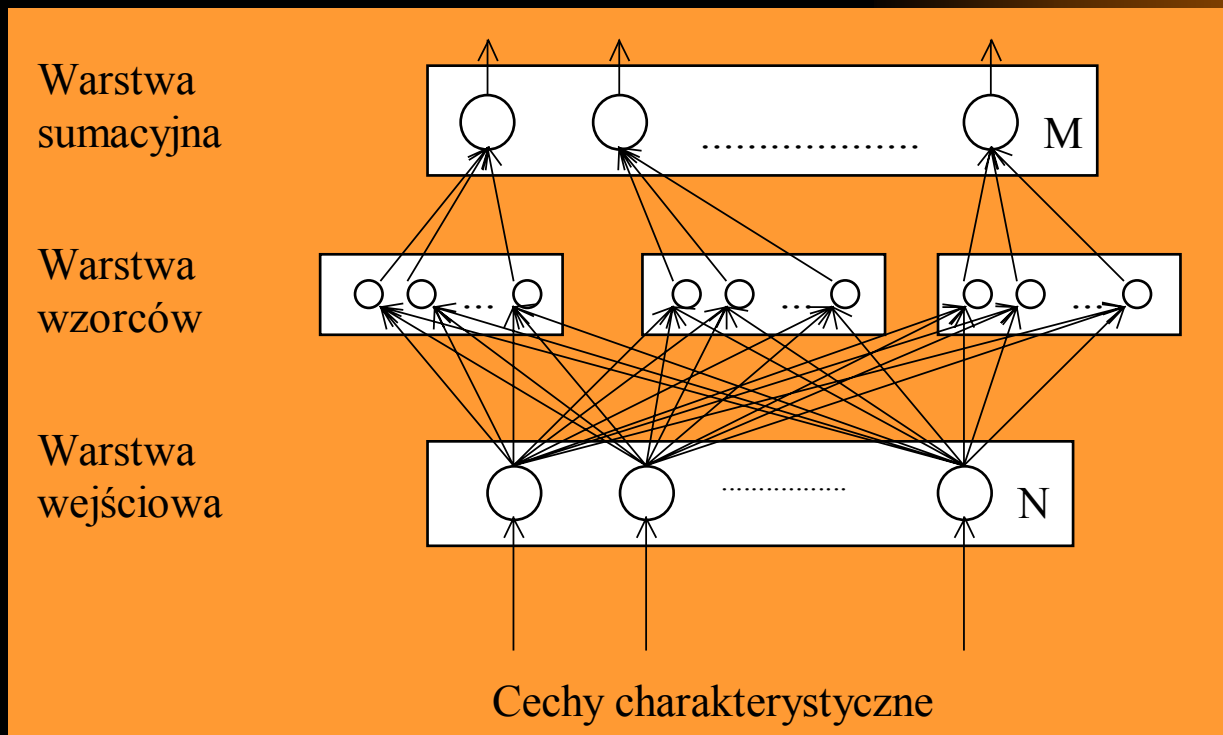
$$y_k(\mathbf{x}) = p(C_k|\mathbf{x})$$

Z drugiej strony uczenie SSN minimalizuje błąd $E_{\mathbf{x}k}$, dlatego: właściwie wytrenowane SSN przybliża prawdopodobieństwa a' posteriori poszczególnych klas abstrakcji C_k

Probabilistyczne sieci neuronowe

- Są dedykowane do zadań klasyfikacji statystycznej
- Uczenie jednoprzebiegowe
- Są specjalizowanymi sieciami RBF dedykowanymi do generowania estymatorów jądrowych gęstości warunkowych prawdopodobieństw wykorzystywanych w klasyfikacji statystycznej

Probabilistyczne sieci neuronowe - struktura



Probabilistyczne sieci neuronowe - estymacja jądrowa

Oznaczenia:

zbiór $V_j = \{\mathbf{x}(s) \in \mathfrak{R}^N, 1 \leq s \leq S_j\}$ wektorów cech należących do klasy C_j

$$\hat{p}(\mathbf{x}|C_j) = \frac{1}{S_j} \sum_{\mathbf{x}(s) \in V_j} \frac{1}{h(s, j)^N} K\left(\frac{\mathbf{x} - \mathbf{x}(s)}{h(s, j)}\right)$$