

Цей винахід пов'язаний із системою та способом оконтурювання вуглеводневих скупчень. Зокрема, цей винахід має відношення до способу та системи з використанням нейронної мережі для оконтурювання просторово залежних об'єктів, таких як вуглеводневі скупчення, із сейсмічних даних.

1. Галузь винаходу

Даний винахід пов'язаний із системою, способом та процесом оконтурювання об'єктів у одномірному (1), двомірному (2) або тримірному (3) просторі на основі даних, що містять картини, пов'язані з існуванням зазначених об'єктів. Наприклад, сейсмічні дані часто містять картини, за якими можна виявити вуглеводневі скупчення шляхом ідентифікації яскравих плям, неконтрастних плям або неясних плям. У минулому, коли нейронні мережі використовувалися для аналогічних потреб, але з іншою метою, ніж виявлення вуглеводневих скупчень, для визначення навчальних наборів даних треба було брати дані, одержані для таких областей, де заздалегідь було відомо, що певні умови існують або не існують. У випадку вуглеводневих скупчень, до розкриття цього винаходу використання такої методики вимагало б буріння нафтових та газових свердловин, яке потребує чималих витрат, для того, щоб зібрати дані для навчальних наборів. У способі, який розкривається у цьому винаході, не вимагається обов'язкове використання наборів напевно відомих навчальних даних для характеристики різних просторово залежних об'єктів, таких як вуглеводневі скупчення. Спосіб, який розкривається у цьому винаході, дозволяє автоматизувати процес інтерпретації даних і швидко одержувати важливу інформацію про місцезнаходження вуглеводневих скупчень навіть до початку буріння.

Автоматизоване оконтурювання вуглеводневих скупчень на основі даних сейсмічної розвідки використовується як один із можливих практичних прикладів для того, щоб описати систему, спосіб та процес, що складають предмет даного винаходу. Проте, спосіб, який розкривається у даному винаході, може знайти широкий спектр використань, інших ніж пошук вуглеводневих скупчень. Наприклад, це можуть бути, без обмеження переліченим, аеромагнітні профілі, астрономічні кластери за радіотелескопічними даними, метеорологічні кластери за даними радіометрів, об'єкти за даними радарів чи гідролокаторів, або за даними інфрачервоних ехо-сигналів тощо. Багато інших можливостей застосування цього винаходу будуть очевидними для спеціалістів відповідних галузей. Отже, передбачається, що додана формула винаходу охоплює усі такі його застосування, які відповідають справжній суті та обсягу цього винаходу.

2. Характеристика попереднього рівня техніки

Багато організацій, як комерційних, так і державних, мають потребу у розпізнаванні об'єктів за картинами, що утворюються даними, зібраними шляхом певних сенсорних процесів сприймання інформації. Просторове оконтурювання таких об'єктів часто є першим кроком у напрямку їх ідентифікації. Раніше для оконтурювання та ідентифікації даного типу часто використовувався метод нейронних мереж. Проте, до існування цього винаходу метод нейронних мереж у загальному випадку вимагав використання напевно відомих даних для створення навчальних наборів, які використовуються як вхідні дані у процесі обробки інформації методом нейронних мереж. Але одержання напевно відомих даних часто є дуже тривалим процесом, який потребує чималих витрат.

Наприклад, у нафтогазовій промисловості зазвичай дані сейсмічної розвідки підлягають інтерпретації, яка є дуже трудомістким процесом. Крім того, така інтерпретація вимагає використання зусиль висококваліфікованого, а, отже, і високооплачуваного персоналу, продуктивність якого обмежується тією кількістю даних, яку фізично можна обробити за заданий період часу. Навіть, якщо люди, що займаються інтерпретацією, дуже кваліфіковані та досвідчені, все ж вони здатні лише на суб'єктивні припущення щодо можливих місць існування вуглеводневих скупчень. Наявність точного та чітко визначеного ареалу можливих вуглеводневих скупчень, тобто колекторів вуглеводнів, або їх просторове оконтурювання, до початку процесу інтерпретації дозволить значно підвищити точність та якість інтерпретації, таким чином зменшуючи ризик, пов'язаний з бурінням. Буріння нафтових та газових свердловин, як правило, виливається у затрату мільйонів доларів за кожну свердловину, а дані розвідки свердловини - тобто, напевно відомі дані - неможливо одержати доти, доки свердловину не пробурили.

Патент США №5,884,295, у якому розкривається «Система для інтерпретації аеромагнітних даних методом нейронних мереж», належить «Техасо, Інс.» - одній з провідних світових нафтових компаній. У цьому патенті розкривається «система для обробки даних аеромагнітної зйомки для визначення відстані до підстильної породи»; і хоча цей винахід не має відношення до способу, що розкривається у даному винаході, він цікавий тим, що звертає увагу на «високу вартість буріння глибоких розвідувальних свердловин та одержання даних сейсморозвідки методом відображених хвиль.»

Патент США №5,444,619 (який цим посиланням включається до тексту даної заявки) належить «Schlumberger Technology» - провідній організації у галузі обробки сейсмічних даних. У цьому патенті винахідники заявляють, що «сейсмічні дані регулярно та ефективно використовуються для оцінки структури колектору, але часто не відіграють жодної ролі у вирішенні важливої задачі оцінки просторового розподілу характеристик колектору. Карта характеристик колектору, як правило, укладається виключно виходячи з результатів розвідки свердловини, навіть коли існують тримірні сейсмічні дані одержані методом високого розділення». У патенті фірми «Schlumberger» пропонуються засоби екстраполяції даних розвідки свердловини на усе родовище на основі сейсмічних даних; проте, у цьому патенті не передбачаються засоби просторового оконтурювання характеристик колектору, таких як газові шапки, зони проникності, зони пористості тощо, до одержання даних розвідки свердловини.

Спосіб, який розкривається у цьому винаході, пропонує процес просторового оконтурювання скупчень різного типу та з різними властивостями. Наприклад, пропонується автоматизований процес оконтурювання вуглеводневих скупчень на основі сейсмічних даних. Одним з конкретних прикладів вуглеводневих скупчень є скупчення газу під покривними породами, тобто, газова шапка, на нафтовому або нафтогазовому чи газовому родовищі. Існування можливості точного оконтурювання газових шапок, виходячи з даних двомірної та тримірної сейсмічної розвідки, навіть до початку процесу інтерпретації даних було б дуже цінним для нафтогазової промисловості. Дивися, наприклад, патенти США за номерами 4,279,307, 3,788,398, 4,183,405 та 4,327,805. В усіх цих патентах, різні способи та процеси, що використовуються для підвищення ефективності

видобування вуглеводнів, базуються на попередньому знанні інформації про газові шапки. Точне оконтурювання газових шапок на основі сейсмічних даних розвідки є давньою та важливою потребою нафтогазової промисловості.

Існують численні патенти США з питань машинного бачення, розпізнавання контурів образу, візуального розпізнавання, розпізнавання зображень, зчитування границь зображення, розпізнавання об'єктів, визначення знаходження об'єктів, виділення границь зображення тощо. Дивися, наприклад, патенти США за номерами 5,103,488, 5,111,516, 5,313,558, 5,351,309, 5,434,927, 5,459,587, 5,613,039, 5,740,274, 5,754,709 та 5,761,326, які стосуються питань, опосередковано пов'язаних з предметом даного винаходу. Навіть якщо у деяких випадках наведені патенти пропонують способи, які для певних конкретних об'єктів, що розглядаються у цих патентах, можуть бути кращими за спосіб, що розкривається у цьому винаході, згадані патенти вказують на потенційно широкий спектр можливих застосувань новизни цього винаходу та на важливість предмету цього винаходу. Крім того, спеціалісти відповідних галузей знайдуть багато інших можливостей застосування цього винаходу. Отже, передбачається, що додана формула винаходу охоплює усі такі його застосування, які відповідають справжній суті та обсягу даного винаходу. Крім патентів, наведених вище, є інші патенти США, де також існують посилання на ряд конкретних прикладів, до яких може бути застосований і предмет даного винаходу.

У патенті США №5,214,744 винахідники, описуючи спосіб автоматичної ідентифікації цілей за гідроакустичними картинами, зауважують, що «зашумленість гідроакустичних зображень перешкоджає використанню операторів лінії та виділення країв». У загальному випадку, дані сейсмічної розвідки також вважаються сильно зашумленими. Проте, як було показано вище, даний винахід пропонує процес точного оконтурювання вуглеводневих скупчень безпосередньо із сейсмічних даних. Отже, можна сподіватися, що як мінімум у деяких випадках цей винахід може запропонувати іншу і, можливо, кращу технологію виконання завдання, яке розглядається у згаданому на початку цього параграфа патенті, що стосується гідролокатора.

У патенті США №5,732,697 описуються «Інваріантні по відношенню до зсуву нейронні мережі для комп'ютерного виявлення кластерних мікроскопів у маммографії». У цьому патентному описі «ряди цифрових медичних зображень використовуються для навчання штучних нейронних мереж відрізняти хворі тканини від нормальних». Цей винахід може бути також застосований для оконтурювання хворих тканин та виділення їх з нормальних або здорових тканин.

У патенті США №5,775,806 описується «Інфрачервона система оцінки», призначена для оцінки «функціонального статусу об'єкта шляхом аналізу його динамічних теплових характеристик, використовуючи ряди інфрачервоних зображень». Даний винахід також може бути застосований для оконтурювання зон з різною функціональністю у рядах інфрачервоних зображень.

У патенті США №5,776,063 «Аналіз ультразвукових зображень у присутності засобу для підсилювання контрасту» описується «система аналізу, призначена для виявлення «текстурних» характеристик, які відрізняють здорові тканини від хворих». У наведеному патенті також зазначається, що винахід «може бути застосований для характеристики двомірних зображень, одержаних за допомогою рентгеноскопії, приладів магнітно-резонансного формування зображень, комп'ютерної томографії, позитронно-емісійної томографії, SPECT тощо та інших методик, пов'язаних із створенням зображень. Даний винахід також може бути застосований для оконтурювання текстурних характеристик, які відрізняють хворі тканини від здорових.

У патенті США № 5,777,481 «Виявлення льоду за допомогою радіометрів» описаний винахід, у якому використовується «атмосферна радіація як індикатор атмосферних умов».

Даний винахід може бути застосований для оконтурювання зон атмосферних водяних парів, хмарної води та льоду; він також може застосовуватися разом із предметом наведеного вище патенту для визначення вмісту оконтурених зон.

Останнім часом було опубліковано багато досліджень, пов'язаних із застосування штучних нейронних мереж у різних контекстах. Деякі приклади таких досліджень згадуються у наведених вище Патентах США. Отже, мета даного винаходу полягає не в тому, щоб навчити будувати нейронні мережі, а, скоріше, в описі того, як їх можна використовувати для оконтурювання просторово залежних об'єктів за картинами, що утворюються даними, зібраними шляхом певного сенсорного процесу сприймання інформації, зокрема - для оконтурювання вуглеводневих скупчень за сейсмічними даними, проблема якого існувала задовго до появи цього винаходу.

Хоча існує багато різних типів штучних нейронних мереж, двома найбільш поширеними є штучні нейронні мережі зворотного розповсюдження помилки навчання та радіальної базисної функції (RBF/radial basis function/). Обидві ці архітектури нейронних мереж, так само як і мережі інших архітектур, можуть бути застосовані у способі, системі та процесі, які розкриваються у цьому винаході. Проте, приклади втілення винаходу, що будуть використані для розкриття способу, системи та процесу, які складають предмет цього винаходу, базуються на моделі зворотного розповсюдження помилки навчання.

У цьому винаході описані та використані система і спосіб, що розкриваються у заявці на патент США 08/974,122, «Оптимальне припинення навчання у нейронних мережах», поданій паралельно з цією заявкою, яка цим посиланням вводиться до даного тексту. Проте, система і спосіб, що розкриваються у заявці, поданій паралельно з даною, у цьому випадку використовуються виключно як допоміжні для системи, способу та процесу, які розкриваються у цій заявці. Вони не є важливими для застосування системи, способу та процесу, які розкриваються у цій заявці.

Таким чином, очевидно, що у різних галузях спеціалісти звичайної кваліфікації знайдуть широкий спектр застосувань для предмета даного винаходу. Отже, передбачається, що додана формула винаходу охоплює усі такі його застосування, які відповідають справжній суті та обсягу цього винаходу.

Також очевидно, що вже давно відчувається потреба у можливості точного оконтурювання просторово залежних об'єктів за картинами, які утворюються даними, зібраними за допомогою певних сенсорних процесів сприймання інформації. Цей винахід пропонує такі систему, спосіб та процес.

Вищезазначена давно існуюча потреба задовольняється цим винаходом, у якому описані система, спосіб

та процес оконтурювання просторово залежних об'єктів за картинами, утвореними даними, зібраними шляхом певного сенсорного процесу сприймання інформації.

Отже, мета даного винаходу - це розкриття того, як можна використовувати нейронні мережі для оконтурювання просторово залежних об'єктів за картинами, утвореними даними, зібраними шляхом певного сенсорного процесу сприймання інформації.

Ще однією метою даного винаходу є розкриття того, як цю методику можна застосовувати для автоматизованого оконтурювання вуглеводневих скупчень із сейсмічних даних.

Ще однією метою даного винаходу є розкриття того, як можна визначити відповідну кількість вузлів та відповідну функцію активації до початку загального процесу оконтурювання.

Ще однією метою даного винаходу є розкриття системи, способу та процесу для швидкого оконтурювання просторово залежних об'єктів за картинами, що утворюються даними, зібраними шляхом певного сенсорного процесу сприймання інформації, коли існують часткові відомості або можливі інтуїтивні припущення щодо приблизного оконтурювання.

Ще однією метою даного винаходу є розкриття системи, способу та процесу для визначення напрямку, в якому знаходиться об'єкт, скупчення або кластер, коли ковзне вікно, яке складає предмет даного винаходу, розташоване на краю об'єкта, скупчення або кластера.

Ще однією метою даного винаходу є забезпечення системи, способу та процесу для оконтурювання просторово залежних об'єктів за картинами, що утворюються даними, зібраними шляхом певного сенсорного процесу сприймання інформації, коли не існує жодних попередніх відомостей або можливостей інтуїтивних припущень щодо їх оконтурювання.

Ще однією метою даного винаходу є забезпечення системи, способу та процесу для визначення того, чи взагалі існують помітні об'єкти серед даних, зібраних за допомогою певного сенсорного процесу сприймання інформації. Наприклад, чи взагалі можливо оконтурити зони, характерні для колекторів вуглеводнів, у межах площі, що охоплюється даною сейсмічною розвідкою. Ця мета досягається як тоді, коли є попередні відомості щодо існування зазначених оконтурень, скупчень, зон чи кластерів, так і тоді, коли таких попередніх відомостей немає.

Ще однією метою даного винаходу є забезпечення системи, способу та процесу для відокремлення різних підоб'єктів, підобластей або субкластерів, що можуть існувати в межах заданого набору даних, одержаних за допомогою певного сенсорного процесу сприймання інформації. Наприклад, відокремлення газових шапок від водонафтового контакту (OWC /oil water contact/) нафтогазового родовища, виходячи з сейсмічних даних або відокремлення зон з різною пористістю, проникністю чи продуктивністю в межах одного колектору вуглеводнів. Ця мета досягається як тоді, коли є попередні відомості щодо існування зазначених субоконтурень, субскупчень, підобластей або субкластерів, так і тоді, коли таких попередніх відомостей немає.

Ще одна мета даного винаходу полягає у розкритті способу внутрішнього підтвердження точності оконтурень, одержаних за допомогою системи, способу та процесу, які розкриваються у даному винаході.

Ще одна мета даного винаходу - показати, як загальні концепції, які розкриваються у даному винаході, можуть застосовуватися у різних галузях, проектах, та фізичних втіленнях винаходу, і задати конкретні характеристики різних сенсорних вхідних даних та/або різних вихідних вимог.

Ще одна мета даного винаходу - показати, як загальні концепції, які розкриваються у даному винаході, можуть втілюватися паралельно на різних комп'ютерах та можуть бути вбудовані безпосередньо в апаратні засоби для прискорення процесу обробки даних.

Нарешті, ще однією метою даного винаходу є забезпечення системи, способу та процесу для передбачення поведінки майбутніх колекторів, тобто моделювання колекторів. Ця мета досягається шляхом виявлення та оконтурювання вуглеводневих вуглецевих скупчень і розбиття скупчень на зони безпосередньо виходячи з даних сейсмічної розвідки, з попередніми відомостями щодо часу завершення, продуктивності та розподілу тисків. Таким чином забезпечується спосіб моделювання колекторів на основі фактичних параметрів, які існують у конкретному скупченні вуглеводнів.

Згідно із зазначеними та іншими аспектами мети винаходу, система, спосіб та процес, що розкриваються у цьому винаході, базуються на використанні нейронної мережі для того, щоб відрізнити відмінні зони, скупчення або кластери, які можна виявити за картинами, що утворюються даними, зібраними шляхом певного сенсорного процесу сприймання інформації. Нейронна мережа класифікує конкретні ділянки даних як такі, що входять (IN) або не входять (OUT) до конкретної зони, конкретного скупчення або кластера.

Перелічені вище, а також інші об'єкти, особливості та переваги даного винаходу стануть очевидними з поданого нижче докладного письмового викладення винаходу.

Запропонований спосіб автоматизованого оконтурювання вуглеводневих скупчень із сейсмічних даних, зібраних на існуючих або можливих нафтових та нафтогазових або газових родовищах, включаючи стадії розробки нейронної мережі з використанням даних розвідки свердловин, які вказують на продуктивні зони, та даних розвідки свердловин, які вказують на непродуктивні зони, і застосування нейронної мережі, як мінімум, до частини сейсмічних даних для того, щоб відрізнити продуктивні зони нафтового родовища від непродуктивних зон. Дані розвідки свердловин, що вказують на продуктивні зони, можуть бути зібрані із свердловин, які існують, або із свердловин, буріння яких систематично планується на основі інформації, одержаної за допомогою цього винаходу. Також дані, що вказують на непродуктивні зони, можуть бути зібрані або в зонах, які за припущеннями мають бути непродуктивними, або з безрезультатних, тобто сухих свердловин. Сейсмічні дані можуть бути одержані шляхом реєстрації сейсмічних або інших прийнятих даних дії динаміту, вібросейсу (генератора безперервних коливань регульованої частоти), тампера (ударного джерела сейсмічних хвиль), ядерного вибуху, землетрусу або іншої технології чи природного явища, що утворюють ударні хвилі, або шляхом реєстрації даних будь-якого іншого типу, які використовуються для відображення або візуалізації характеристик нижніх горизонтів землі. Цей спосіб може також використовуватися для виділення певних підобластей основних скупчень, таких як зони пористості, проникності, високої чи низької продуктивності тощо.

Одним з варіантів втілення винаходу є спосіб оконтурювання вуглеводневих скупчень на базі сейсмічних даних, зібраних на нафтовому або нафтогазовому чи газовому родовищі, навіть якщо буріння свердловин взагалі не проводилося, включаючи стадії розробки нейронної мережі, обмеженої концептуальним ковзним вікном, для виділення скупчень, і застосування нейронної мережі як мінімум до частини даних сейсмічної розвідки для того, щоб відрізнити характеристики, властиві колекторам вуглеводнів, від характеристик тих областей, де немає колекторів вуглеводнів. Ковзне вікно може поділятися на блоки «In» та «Out».

Ще одним із варіантів втілення винаходу є спосіб оконтурювання мінеральних скупчень на базі даних, пов'язаних із заданою зоною, включаючи стадію розробки нейронної мережі для того, щоб відрізнити продуктивні зони від непродуктивних в межах заданої зони, і стадію застосування нейронної мережі як мінімум до частини даних для того, щоб відрізнити продуктивні зони від непродуктивних. Дані, що для цього використовуються, можуть бути сейсмічними, аеромагнітними, гравітаційними або будь-якими іншими підходящими даними.

Ще одним із варіантів втілення винаходу є спосіб оконтурювання просторово залежних характеристик в межах заданої зони на основі даних, пов'язаних з такою зоною, включаючи стадії розробки нейронної мережі для виявлення та оконтурювання аномалій, і застосування нейронної мережі як мінімум до частини даних для того, щоб оконтурити аномалії в межах заданої зони. Характеристики можуть бути пов'язані з температурою, відмінними властивостями тканин, складом матеріалу, що знаходиться у даній зоні тощо.

Ще одним із варіантів втілення винаходу є спосіб визначення точності нейронної мережі, що була використана для оконтурювання просторово залежних об'єктів, на базі даних, пов'язаних із заданою зоною, включаючи стадії розробки первинної нейронної мережі для виявлення та оконтурювання аномалій в межах заданої зони, застосування первинної нейронної мережі як мінімум до частини даних для створення кількісних оцінок, пов'язаних з підобластями заданої зони, коли високі та низькі чисельні показники вказують на наявність або відсутність об'єктів в межах даної області, створення навчальних наборів та тестових наборів з використанням даних, пов'язаних з підобластями, які характеризуються високими або низькими значеннями кількісних оцінок порівняно з іншими підобластями, розробки вторинної нейронної мережі з використанням навчальних та тестових наборів даних для виявлення та оконтурювання аномалій в межах заданої зони, застосування вторинної нейронної мережі як мінімум до частини даних для створення кількісних оцінок, пов'язаних з підобластями заданої зони, та порівняння результатів використання первинної, вторинної, третинної тощо нейронних мереж з метою визначення точності нейронної мережі, яка була застосована для виділення заданих даних.

Елементи новизни, властиві цьому винаходу, викладені у доданій формулі винаходу. Проте сам винахід, так само як і оптимальний засіб його застосування та інші його об'єкти, ракурси і переваги, краще за все стануть зрозумілими з викладеного нижче детального опису наведеного як ілюстративний приклад варіанту втілення винаходу, якщо його сприймати у супроводі доданих фігур, де

Фіг.1 - це схематична діаграма нейронної мережі;

Фіг.2 є схематичною діаграмою концептуального ковзного вікна, яке використовується у даному винаході;

Фіг.3 показує інформаційний потік між шарами нейронної мережі у разі зворотного розповсюдження помилки навчання;

Фіг.4 показує нейронну мережу з вхідним шаром, схованим шаром та вихідним шаром;

Фіг.5 відображає залежність між навчальним набором даних, тестовим набором даних та повним масивом даних;

Фіг.6 показує стадії, необхідні для навчання нейронної мережі;

Фіг.7 (а) відображає функцію активації з жорсткими обмеженнями;

Фіг.7 (b) відображає порогову логічну функцію активації;

Фіг.7 (c) відображає симіодальну функцію активації;

Фіг.8 показує варіант втілення вузла нейронної мережі;

Фіг.9 відображає модель нейронної мережі із зазначенням вагових коефіцієнтів;

На Фіг.10 середньоквадратична помилка порівнюється з дисперсією тестового набору даних;

Фіг.11 - це блок-схема типового процесу оконтурювання просторово залежного об'єкта;

Фіг.12 відображає гіпотетичний сейсмічний план;

Фіг.13 показує сейсмограму загальної глибинної точки (CDP /Common Depth Point/);

Фіг.14 відображає гіпотетичний сейсмічний план із розщепленим ковзним вікном;

Фіг.15 відображає гіпотетичний сейсмічний план гіпотетичного нафтогазового родовища.

Докладний опис оптимального варіанту втілення винаходу визначення

«Вузол» означає одиничний нейроноподібний обчислювальний елемент нейронної мережі.

«Ваговий коефіцієнт» означає регульовану величину або параметр, пов'язану(ий) із сполученням між вузлами у нейронній мережі. Величина вагового коефіцієнту визначає інтенсивність сполучення. Від'ємні вагові коефіцієнти перешкоджають активізації вузла, а додатні вагові коефіцієнти розблоковують активізацію вузла.

«Сполучення» означають проходи між вузлами, подібні до аксонів та синапсів нейронів людського мозку, які сполучають вузли у нейронну мережу.

«Закон навчання» означає рівняння, за яким змінюються усі або деякі з вагових коефіцієнтів локальної пам'яті вузла у відгук на вхідні сигнали та величини, що подаються функцією активації. Це рівняння дозволяє нейронній мережі адаптуватися до прикладів того, що їй треба робити, та організовувати свій внутрішній інформаційний потік і, таким чином, вчитися. Закони навчання для регулювання вагових коефіцієнтів можуть бути охарактеризовані як кероване навчання, некероване навчання та закріплюване навчання. Кероване навчання означає, що бажаний вихідний сигнал вузла відомий або може бути визначений з сумарної помилки. Тоді його значення використовується для формування сигналу помилки, який, у свою чергу, використовується для зміни вагових коефіцієнтів. У некерованому навчанні бажаний вихідний сигнал невідомий і навчання базується на значеннях вхідних/вихідних величин. У методі закріплюваного навчання пов'язані з вузлом вагові

коефіцієнти не змінюються пропорційно вихідній помилці, що пов'язується з конкретним вузлом, а замість того змінюються пропорційно глобальному сигналу закріплення певного типу.

«Функція активації» або «передаточна функція» - це формула, яка визначає вихідний сигнал на вузлі як функцію самих останніх значень вхідних сигналів та вагових коефіцієнтів, що зберігаються у локальній пам'яті.

«Зворотне розповсюдження помилки навчання» у нейронній мережі - це метод керованого навчання, у якому вихідний сигнал помилки передається назад крізь мережу і змінює вагові коефіцієнти сполучення таким чином, щоб мінімізувати помилку.

«Вхідний шар» - це шар вузлів, який утворює пасивний канал введення даних до нейронної мережі.

«Схований шар» - це шар вузлів, не зв'язаних безпосередньо з вхідними або вихідними сигналами нейронної мережі.

«Вихідний шар» - це шар вузлів, який видає результати роботи нейронної мережі.

«Оптимальна точка навчання» - це такий момент процесу навчання нейронної мережі, коли дисперсія нейронної мережі досягає мінімуму по відношенню до результатів, одержаних на тестовому наборі даних 202, який, у випадку цього винаходу, береться з концептуального ковзного вікна 205, що включає дані, одержані за допомогою певного сенсорного процесу сприймання інформації.

Загальне уявлення про винахід

Описаний нижче винахід пов'язаний в цілому із способом та системою обробки даних, а зокрема - із способом та системою автоматизованого оконтурювання аномалій або об'єктів в одновимірному, двовимірному та тривимірному просторі на основі даних, що утворюють картини, пов'язані з існуванням об'єктів. Наприклад, дані сейсмічної розвідки часто утворюють картини, за якими, використовуючи цей винахід, можна знайти та оконтурити вуглеводневі скупчення шляхом застосування нейронних мереж. Використання винаходу зазначеним вище чином може складатися з таких стадій. Перша - розробка нейронної мережі. Друга - застосування нейронної мережі до усіх даних сейсмометричних досліджень. Третя - використання нейронної мережі для передбачення продуктивності майбутніх свердловин.

Викладений нижче стислий опис дає загальне уявлення про винахід. Винахід базується на використанні нейронної мережі для відрізнєння відмінних районів, скупчень або кластерів вуглеводневих скупчень, які можна виявити за картинами, що утворюються даними сейсмічної розвідки. Нейронна мережа класифікує конкретні області даних як такі, що входять (In) або не входять (Out) до конкретної зони, конкретного скупчення або кластера. Цей винахід забезпечує спосіб автоматизації процесу аналізу та інтерпретації даних сейсмічної розвідки.

Для того, щоб зрозуміти, як відбувається цей процес, припустимо, що нейронна(i) мережа(i) має(ють) архітектуру 101, показану на Фіг.1, яка складається з вхідного шару, одного або декількох схованих шарів та вихідного шару, де кожен шар містить один або декілька вузлів і усі вузли вхідного шару сполучаються з суміжними але різними частинами даних від певного сенсорного процесу сприймання інформації. Кожен вузол вхідного шару сполучений з кожним з вузлів першого і, можливо, єдиного схованого шару; кожен вузол першого схованого шару сполучений з кожним із вузлів наступного схованого шару, якщо він існує, а кожен із вузлів останнього схованого шару сполучений з кожним з вузлів вихідного шару. Кожен зв'язок між вузлами має відповідний ваговий коефіцієнт. Вихідний шар видає на виході класифікацію 109 (описану нижче). Потім нейронна мережа враховує процес навчання (не показаний на Фіг.1) для визначення вагових коефіцієнтів кожного зі сполучень нейронної мережі.

Далі, як показано на Фіг.2, для двовимірного випадку, що розглядається як ілюстративний приклад, припускаємо існування концептуального ковзного вікна (докладніше описаного нижче), що представляє собою комбінацію навчального/тестового наборів даних і складається з трьох суміжних ліній, кожна з яких містить лінійно суміжні частини даних, одержаних за допомогою певного сенсорного процесу сприймання інформації. Середня з цих трьох ліній, зображених на Фіг.2, середня відповідає навчальному набору даних 201, тоді як дві інші лінії складають тестовий набір 202. Бажано, щоб приблизно половині даних кожної з трьох ліній присвоювалася класифікація «Out», а другій половині даних присвоювалася класифікація «In». Кожна з трьох ліній даних є суміжною з кожною з інших ліній, а кожна точка даних на кожній з таких ліній є лінійно суміжною з її найближчими сусідніми точками даних. Класифікації «In» та «Out» є суміжними та охоплюють, приблизно, половину точок даних на кожній з суміжних ліній. І, нарешті, всі лінії, яких для прикладу показано три, є просторово орієнтованими по відношенню одна до одної.

Ковзне вікно, що використовується у цьому винаході - це концептуальна вигадка для спрощення розуміння винаходу читачем. Отже, передбачається, що додана формула винаходу охоплює усі такі його застосування, які відповідають справжній суті та обсягу цього винаходу, незалежно від термінології, яка може використовуватися для характеристики системи, способу або процесу.

У процесі навчання здійснюється ітераційне введення навчального набору даних 201 до нейронної мережі, де навчальний набір утворюється з середньої лінії ковзного вікна, яка складається з даних, одержаних за допомогою певного сенсорного процесу сприймання інформації. Після кожної ітерації процесу навчання визначається різниця між класифікацією, яку видає нейронна мережа, та заданою класифікацією даних, що складають навчальний набір. Далі навчальний набір даних регулює вагові коефіцієнти нейронної мережі відповідно до цієї різниці. Помилка, яка ставиться у відповідність кожному з вузлів мережі, може задаватися у процесі навчання шляхом зворотного розповсюдження помилки навчання.

Як докладніше описується нижче, момент припинення навчання оптимізується шляхом виконання наступного процесу після кожної з навчальних ітерацій: зберігання вагових коефіцієнтів нейронної мережі, яким присвоюється номер ітерації; тестування нейронної мережі на тій частині даних ковзного вікна, які складають тестовий набір 202 і які не залежать від даних навчального набору 201; обчислення різниці між класифікацією, яку видає нейронна мережа для тестового набору даних, та наперед відомою класифікацією тестового набору даних, яка у цьому випадку називається дисперсією; збереження номера ітерації та поточного значення дисперсії, якщо поточне значення дисперсії є меншим за будь-яке з попередніх; відслідковування значень дисперсії доти, доки не буде визначено, що дисперсія починає зростати, замість

того, щоб зменшуватися.

У точці, для якої було визначено, в межах певної заданої наперед припустимої границі помилки, що дисперсія починає зростати (дивися, наприклад, точку номер 1005 на Фіг.10), відбувається припинення процесу навчання. Потім номер тієї ітерації, у якій було досягнуте найнижче значення дисперсії, використовується для зчитування з пам'яті оптимального набору вагових коефіцієнтів нейронної мережі для даної позиції ковзного вікна. Дисперсія між оптимальною підгонкою результатів до тестового набору даних та наперед заданими значеннями тестового набору даних може бути одержана або шляхом застосування оптимального набору вагових коефіцієнтів нейронної мережі до тестового набору даних, або шляхом зчитування з пам'яті значення дисперсії, якщо воно було перед тим збережене в процесі навчання під час ітераційної процедури.

Далі ковзне вікно 205 переміщається вперед на одну точку повного масиву даних, зібраних шляхом сенсорного процесу сприймання інформації. Тобто починаючи зліва, перші точки «Out» кожної з трьох ліній випадають з відрізків ліній, що обмежуються ковзним вікном. Далі, перші три точки «In» стають точками «Out». І нарешті, до ковзного вікна додаються три нові точки «In». Вікно може переміщатися зліва направо, справа наліво, зверху вниз або знизу вгору.

Потім процес навчання нейронної мережі починається знову та закінчується новим значенням дисперсії в оптимальній точці припинення навчання. Доти, доки ковзне вікно знаходиться повністю за межами зони, скупчення або кластера, значення дисперсії для усіх позицій ковзного вікна залишатимуться високими та близькими до постійної величини. Як тільки ковзне вікно натрапляє на зону, скупчення або кластер, які необхідно виявити, значення дисперсії починають падати та досягають мінімуму тоді, коли центр ковзного вікна знаходиться на краю зони, скупчення або кластера, які необхідно виявити.

Після того як зону, скупчення або кластер виявлено, можна оконтурити відповідний об'єкт шляхом подачі повного масиву даних на нейронну мережу з тими ваговими коефіцієнтами, які були одержані у процесі пошуку краю об'єкта.

Нижче поданий більш докладний опис оптимального варіанту втілення винаходу. Предметом цього винаходу є метод нейронної мережі та система для оконтурювання просторово залежних об'єктів, таких як вуглеводневі скупчення. Процес базується на використанні нейронної мережі для генерування класифікації. На Фіг.1 зображені нейронна мережа 101, вхідні дані, що поступають з ковзного вікна 105, блок попередньої обробки даних 107 та класифікація «In» або «Out» (109). Нейронна мережа 101 генерує класифікацію 109 виходячи з вхідних даних, що подаються на вхідний шар мережі. Вхідна інформація, що подається на нейронну мережу, вибирається з даних, одержаних за допомогою певного сенсорного процесу сприймання інформації. Блок попередньої обробки 107, зображений на Фіг.1, може здійснити попередню обробку даних, що подаються на вхід нейронної мережі.

Процес попередньої обробки можна застосовувати, наприклад, для нормування вхідних даних.

На Фіг.2, у припущенні певної системи класифікації зображене ковзне вікно 205 для виявлення та оконтурювання можливих колекторів вуглеводнів на основі сейсмічних даних, яке включає комбінацію навчального набору даних 201 та тестового набору даних 202. Ковзне вікно 205, яке включає комбінацію навчального набору/тестового набору, у даному варіанті втілення винаходу, що розглядається як приклад, складається з трьох суміжних ліній, кожна з яких містить лінійно суміжні частини даних, взятих з даних сейсмічної розвідки, Фіг.14. Середня з трьох ліній, зображених на Фіг.2, тобто лінія 201, відповідає навчальному набору даних, тоді як дві зовнішні лінії 202 утворюють тестовий набір. Приблизно (та бажано) половині даних кожної з трьох ліній присвоюється класифікація «Out», тоді як другій половині даних присвоюється класифікація «In». Кожна з трьох ліній даних є суміжною з іншими лініями, а кожний з елементів даних є лінійно суміжним з найближчими сусідніми елементами даних 503. Класифікації «In» та «Out» є суміжними та охоплюють, приблизно (і бажано), половину усіх точок даних на кожній з ліній. І, нарешті три лінії є просторово орієнтованими по відношенню одна до одної. На Фіг.5 показана залежність між повним масивом даних 509, ковзним вікном 505, навчальними даними 501 та тестовими даними 502 для довільної точки повного масиву даних, одержаних за допомогою певного сенсорного процесу сприймання інформації.

У цьому винаході розуміється, що для оконтурювання просторово залежних об'єктів можуть використовуватися й інші конфігурації ковзного вікна. Відповідно, передбачається, що додана формула винаходу охоплює усі такі його застосування, які відповідають справжній суті та обсягу цього винаходу.

Нейронна мережа 101 працює у чотирьох основних режимах: навчальному режимі, режимі тестування, операційному режимі та режимі переучування. У режимі навчання здійснюється навчання нейронної мережі 101 за допомогою процесу навчання, у якому на нейронну мережу подаються навчальні набори даних. Навчальний набір 201 складається з лінійно суміжних даних, що приблизно, порівну розподілені між класифікаціями «In» та «Out». Нейронна мережа 101 генерує класифікацію виходячи з подібності або розбіжності даних у навчальному наборі. Ця класифікація потім порівнюється з класифікаціями, попередньо присвоєними точкам навчального набору. Різниця між класифікацією 109, генерованою нейронною мережею, та класифікаціями, присвоєними попередньо, використовується для регулювання вагових коефіцієнтів нейронної мережі. У процесі навчання нейронна мережа вчиться та пристосовується до вхідних сигналів, які на неї подаються, та до кривої середньоквадратичної помилки 1003 (дивися Фіг.10). Крива середньоквадратичної помилки 1003 безперервно спадає зі зростанням кількості ітерацій. Наприкінці кожної ітерації навчального процесу на нейронну мережу подається набір тестових даних 202. Цей тестовий набір 202 складається з суміжних даних, взятих з масиву, одержаного за допомогою сенсорного процесу сприймання інформації. Для тестового набору 202, так само як і для навчального набору даних 201, класифікації «In» та «Out» задаються наперед; проте дані у тестовому наборі 202 не дублюють дані навчального набору 201. Тестовий набір 202 створюється з суміжних ліній, які орієнтовані паралельно лінії навчальних даних та розміщуються по обидві сторони від лінії навчального набору. Значення класифікації, що утворюється в результаті подачі тестового набору даних 202 на нейронну мережу, порівнюється з заданими наперед класифікаціями тестового набору 202, і обчислюється дисперсія 1001. Значення дисперсії 1001

відслідковуються наприкінці кожної ітерації, для того щоб визначити точку, у якій починає зростати дисперсія та крива дисперсії 1001, дивися Фіг.10. У точці, де дисперсія починає зростати - тобто, де досягається мінімум дисперсії, навчання припиняється.

Після закінчення навчання нейронної мережі 101 зображені на Фіг.9 вагові коефіцієнти, які існували у точці досягнення мінімуму дисперсії 1001, беруться з пам'яті, якщо вони були збережені у процесі ітерації, або розраховуються знову з метою одержання оптимального набору вагових коефіцієнтів нейронної мережі для поточної позиції ковзного вікна 205. Значення дисперсії (1001) між значеннями класифікації тестового набору 202, розрахованими нейронною мережею при оптимальному наборі вагових коефіцієнтів у точці припинення навчання, і значеннями класифікації, заданими наперед для тестового набору даних 202, може бути або одержане шляхом застосування оптимального набору вагових коефіцієнтів нейронної мережі до даних тестового набору 202, або може бути взяте з пам'яті, якщо значення дисперсії 1001 було перед тим збережене в процесі навчання під час ітераційних процедур.

Потім ковзне вікно 205 переміщується уперед на одну точку відносно масиву даних, одержаних за допомогою певного сенсорного процесу сприймання інформації. Тобто, починаючи зліва, перші точки «Out» кожної з трьох ліній випадають з відрізків ліній, з яких складається ковзне вікно 205. Далі перші три точки «In» стають точками «Out». І, нарешті, до ковзного вікна 205 додаються три нові точки «In».

Потім процес навчання нейронної мережі починається знову та закінчується новим значенням дисперсії 1001 в оптимальній точці припинення навчання. Доти, доки ковзне вікно знаходиться повністю за межами зони, скупчення або кластера, значення дисперсії залишатимуться високими та близькими до постійної величини для усіх позицій ковзного вікна. Як тільки ковзне вікно натрапляє на зону, скупчення або кластер, які необхідно виявити, величина дисперсії починає падати та досягає мінімуму тоді, коли центр ковзного вікна знаходиться на краю ділянки, скупчення або кластера, які необхідно виявити. Зазначені вище стадії, зображені на Фіг.6, описують режими навчання та тестування нейронної мережі.

Після того як зона, скупчення або кластер виявлено, можна оконтурити відповідний об'єкт шляхом подачі повного масиву даних на нейронну мережу з тими ваговими коефіцієнтами, які були одержані у процесі пошуку краю об'єкта. Цей режим функціонування нейронної мережі називається операційним режимом.

Переваги існування можливості динамічного переривання навчання в оптимальній точці або поблизу оптимальної точки

Нейронні мережі навчаються у процесі навчання, у якому навчальний набір даних ітераційно подається на нейронну мережу крізь вхідний шар 405. Метою навчального процесу є мінімізація середньоквадратичної помилки 1003 по усім конфігураціям навчальних даних. Ця мета досягається шляхом зворотного розповсюдження помилки навчання після кожної ітерації та коригування відповідних вагових коефіцієнтів (Фіг.6). Після достатньої кількості ітерацій вагові коефіцієнти нейронної мережі (Фіг.9) починають сприймати характеристики або картини даних. Раніше, до розробки способу, який розкривається у заявці на патенті США номер 08/974,122 «Оптимальне припинення навчання у нейронних мережах», поданій паралельно з цією заявою (що цим посиланням включається до тексту даної заявки), визначення того, коли нейронна мережа сприйняла відповідний набір характеристик, тобто визначення номера ітерації, у якій це відбулося, складало проблему. В реальних ситуаціях, коли до картин, утворених даними, додаються шуми, загальноприйнятим є порядок, за яким нейронна мережа спочатку пристосовується до основної конфігурації, а потім починає запам'ятовувати дані. Запам'ятовуючи дані, нейронна мережа тим самим сприймає характеристики шумів разом із характеристиками основної конфігурації картини. Це називається надмірним пристосуванням або надмірним навчанням. Ось чому так важливо зупинити навчання в оптимальний момент.

Загальною метою є навчання нейронної мережі до такого моменту, коли основна картина виявлена, а шуми ще не відобразилися на вагових коефіцієнтах. Проте, це було важкою задачею у минулому, до заявки на патент США номер 08/974,122, поданої паралельно з цією заявою. В результаті, типові нейронні мережі попереднього рівня техніки, як правило, навчалися або до досягнення точки, у якій середньоквадратична помилка навчального набору зменшується до заданого рівня, або до перевищення заданої кількості ітерацій.

Спосіб зупинки процесу навчання на попередньому рівні техніки був занадто дорогим за рядом причин. Часто мало місце надмірне навчання нейронних мереж; таким чином, цінний час марнувався на створення нейронних мереж, які недостатньо точно визначають класифікації. Це особливо справедливо, коли йдеться про проблему оконтурювання просторово залежних об'єктів. Той, хто розробляє нейронну мережу, не може сказати наперед, буде чи не буде навчання надмірним або недостатнім, отже, порівняння дисперсій 1001 у різних положеннях буде неточним навіть в оптимальному випадку. Подана паралельно з цією заявою заявка на патент США номер 08/974,122 розкриває спосіб подолання цих обмежень та спрощує розуміння даного винаходу. Тому детальний опис способу і системи, що складають предмет заявки, поданої паралельно з даною, включаються до тексту цієї заявки.

Докладний опис прикладу нейронної мережі

Добре розуміння технології нейронних мереж є дуже корисним для оцінки різних ракурсів та переваг даного винаходу. Тому у наступному розділі обговорюється технологія нейронної мережі стосовно до її оптимального варіанту, що розкривається у цьому винаході. Звісно, предмет винаходу не обмежується типами нейронних мереж, розглянутими у цьому тексті.

Штучні або комп'ютерні нейронні мережі - це комп'ютерні моделі мережі взаємозв'язаних нейронів людського мозку. Треба розуміти, що аналогія з людським мозком є важливою та корисною для розуміння цього винаходу. Проте, нейронні мережі, що розкриваються у цьому винаході, це комп'ютерні моделі, які дозволяють одержати корисні класифікації виходячи з вхідних даних, які задаються у точно визначених формах, а у випадку цього винаходу є даними, зібраними шляхом певного сенсорного процесу сприймання інформації.

Нейронна мережа може бути визначена трьома елементами: набір вузлів, задана топологія зв'язаних взаємозв'язків між вузлами та закон навчання, за яким відбувається коригування вагових коефіцієнтів сполучень. Фактично, нейронна мережа є ієрархічною сукупністю вузлів (відомих також під назвою нейрони

або нейроди, або елементи, або процесорні елементи, або пресептрони), кожний з яких обчислює результати рівняння (передаточної функції або функції активації). Рівняння може включати порогову величину. Функція активації кожного з вузлів використовує множинні значення вхідних сигналів, але генерує тільки одне вихідне значення. Вихідні значення на вузлах нижчого рівня (того, що ближчий до вхідних сигналів) подаються як вхідні сигнали на вузли наступного (вищого) рівня. Найвищий рівень генерує вихідний(і) сигнал(и) мережі. Нейронна мережа, у якій усі вихідні сигнали нижчого рівня поступають на усі вузли наступного вищого рівня, звичайно називається нейронною мережею з прямим зв'язком.

На Фіг.4 зображений характерний приклад нейронної мережі. Слід зазначити, що приклад, представлений на Фіг.4, є просто ілюстрацією одного із варіантів втілення нейронної мережі. У цьому винаході можуть використовуватися і нейронні мережі інших типів, що обговорюється нижче. У варіанті нейронної мережі, зображеному на Фіг.4, мережа має вхідний шар 405, схований (або середній) шар 403 та вихідний шар 401. Вхідний шар 405 містить шар вхідних вузлів, які сприймають вхідні значення 407 від зовнішнього джерела вхідних сигналів, що у випадку цього винаходу складаються з даних певного сенсорного процесу сприймання інформації та наперед заданих значень класифікації «Out»/«In». Вхідні значення використовуються нейронною мережею для генерування вихідних сигналів 409, які відповідають класифікації 109. Хоча вхідний шар 405 називається шаром нейронної мережі, вхідний шар 405 не містить жодних обробляючих вузлів: замість того використовуються набір комірок пам'яті для вхідних значень.

Наступний шар називається схованим або середнім шаром 403. Схований шар не є обов'язковим, але, як правило, використовується у нейронних мережах. Він містить набір вузлів, як показано на Фіг.4. Вихідні сигнали вузлів вхідного шару 405 поступають як вхідні дані на кожний з вузлів схованого шару 403. Відповідним чином, вихідні сигнали вузлів схованого шару 403 поступають як вхідні дані на кожний з вузлів вихідного шару 401. Можуть використовуватися і додаткові сховані шари нейронної мережі. Кожний з вузлів такого додаткового схованого шару сприйматиме на вході вихідні сигнали попереднього схованого шару. Можливе використання будь-якої кількості схованих шарів.

Вихідний шар 401 може складатися з одного або більше вузлів. Вузли вихідного шару сприймають дані на виході з вузлів схованого шару 403 як вхідні дані. Вихідний(і) сигнал(и) вузла(ів) вихідного шару є класифікацією(ями) 409, що генерує(ю)ться нейронною мережею виходячи з вхідних даних 407, які у випадку цього винаходу складаються з даних, одержаних за допомогою певного сенсорного процесу сприймання інформації та з заданих наперед значень класифікації.

Кожний зв'язок між вузлами нейронної мережі має пов'язаний з ним ваговий коефіцієнт, як показано на Фіг.9. Вагові коефіцієнти визначають, який відносний вплив матиме вхідний сигнал на вихідне значення відповідного вузла. Як показано на Фіг.6, перед початком навчання мережі для кожного з вагових коефіцієнтів вибираються довільні значення 600. Вагові коефіцієнти змінюються у міру того, як відбувається процес навчання нейронної мережі. Вагові коефіцієнти змінюються відповідно до закону навчання, пов'язаного з нейронною мережею (що описується нижче).

Коли вхідні сигнали кожного з вузлів шару сполучені з усіма вихідними сигналами вузлів попереднього шару, така мережа називається «повністю зв'язаною». Якщо всі вузли використовують вихідні значення вузлів попереднього шару, мережа називається «нейронною мережею з прямим зв'язком». Зверніть увагу на те, що коли будь-який з вузлів використовує вихідні значення вузлів наступного шару, то ми говоримо, що мережа має зворотний зв'язок. Нейронна мережа, зображена на Фіг.4, є повністю зв'язаною нейронною мережею з прямим зв'язком.

Нейронна мережа будується шляхом задавання номерів, розміщення та сполучень для вузлів, з яких вона складається. У високоупорядкованому варіанті втілення нейронної мережі її конфігурації є досить простими. Наприклад, у повністю зв'язаній мережі з одним середнім шаром без зворотного зв'язку (яка, звичайно ж, містить також один вхідний та один вихідний шар) кількість сполучень і, відповідно, кількість вагових коефіцієнтів задається кількістю вузлів у кожному шарі. Саме цей випадок зображений як приклад на Фіг.4.

У нейронній мережі, яка має вузли з однаковими функціями активації, необхідно визначати загальну кількість вузлів у кожному з шарів. Таким чином визначається кількість вагових коефіцієнтів та загальна кількість комірок пам'яті, необхідних для побудови мережі. Зверніть увагу на те, що більш складні мережі вимагають більше інформації про їхню конфігурацію, а отже - більше пам'яті. У цьому винаході стисло розкривається спосіб вибору належної кількості вузлів та належної функції активації для нейронної мережі, що використовується з метою оконтурювання просторово залежних об'єктів.

Даний винахід допускає використання багатьох інших типів конфігурації нейронної мережі для потреб оконтурювання просторово залежних об'єктів. Усе, що вимагається від нейронної мережі - це здатність до навчання, для того щоб генерувати необхідну(і) класифікацію(ї).

Далі буде описаний, з посиланням на Фіг.4, ілюстративний варіант втілення нейронної мережі з прямим зв'язком. Це - лише ілюстративний приклад одного з можливих варіантів функціонування нейронної мережі. Вхідні дані 407 подаються на вхідні комірки пам'яті, що називаються вхідними вузлами вхідного шару 405. Кожний з вузлів схованого шару 403 одержує вхідні сигнали з усіх вхідних комірок вхідного шару 405. Кожний з вузлів сприймає кожне з вхідних значень з ваговим коефіцієнтом. Кожний вузол множить кожне з вхідних значень на відповідний ваговий коефіцієнт, а потім сумує одержані величини за усіма вхідними сигналами. Ця сума далі використовується як вхідна величина у рівнянні (що також називається передаточною функцією або функцією активації), яке видає вихідний сигнал або активацію для даного вузла. Обробка даних для вузлів схованого шару 403 може здійснюватися або паралельно, або послідовно. Далі, у нейронній мережі з одним єдиним схованим шаром 403, зображений на Фіг.4, обчислюються вихідні значення або активації. На кожний з вузлів вихідного шару подаються вихідні значення або активації з кожного з вузлів схованого шару. Кожне вихідне значення або активація множиться на відповідний ваговий коефіцієнт, а потім одержані величини сумуються. Одержана сума використовується як вхідна величина у рівнянні, в результаті рішення якого генерується вихідне значення або класифікація 409. Таким чином, використовуючи вхідні дані 407, нейронна мережа видає класифікацію або вихідні дані 409. Це і є прогнозованою класифікацією.

Вузли

Типовий вузол зображений на Фіг.8. Вихідний сигнал вузла є нелінійною функцією зваженої суми вхідних сигналів, що поступають на цей вузол. Залежність вхідного/вихідного сигналів вузла часто описується як передаточна функція або функція активації. У більшості нейронних мереж усі рівняння для усіх вузлів є однаковими (хоча вагові коефіцієнти та вхідні сигнали будуть різними). Функцію активації можна представити у символічній формі наступним чином:

$$Y = f(\sum w_i x_i)$$

Саме зважена сума $\sum w_i x_i$ вводиться до функції активації вузла як вхідна величина. Функція активації визначає рівень активності або рівень збудження, що генерується на вузлі в результаті надходження вхідного сигналу певної величини. Будь-яка функція може бути вибрана як активаційна. Проте, для зворотного зв'язку оптимальною є сигмоїдальна функція. Сигмоїдальна функція - це безперервна монотонно зростаюча S-подібна функція, яка асимптотично наближається до постійних значень, коли вхідний сигнал прямує до плюс або мінус нескінченності. Як правило, верхнє граничне значення сигмоїдальної функції задається рівним +1, а нижнє - або 0, або -1. Сигмоїдальна функція показана на Фіг.7(с) і може бути представлена наступним чином:

$$f(x) = 1/(1 + e^{-(x+T)})$$

де x - це зважене вхідне значення (тобто, $\sum w_i x_i$), а T - це просто порогове значення або зміщення.

Зверніть увагу на те, що порогове значення T у наведеному вище рівнянні можна опустити, якщо ввести до нейронної мережі вузол зміщення. Вузол зміщення не одержує вхідних сигналів і подає постійну величину (як правило, +1) на всі вихідні сигнали та на всі сховані вузли нейронної мережі. Вагові коефіцієнти, що задаються кожним з вузлів на цей вихідний сигнал, стають пороговими значеннями відповідних вузлів. Це дозволяє спростити рівняння до $f(x) = 1/(1 + e^{-x})$, де x - це зважений вхідний сигнал (тобто $\sum w_i x_i$, де $x_0 = 1$, а w_0 додається як ваговий коефіцієнт). На Фіг.9, так само як і на Фіг.1, зображена нейронна мережа з вузлом зміщення (тобто $x_0 = 1$).

Повернемося до тришарової мережі із зворотним зв'язком, зображеної на Фіг.9. Ця нейронна мережа має вхідний шар, який подає зважений вхідний сигнал на схований шар; схований шар трансформує цей вхідний сигнал і передає його на вихідний шар, який здійснює подальшу трансформацію та видає вихідну класифікацію. У цьому прикладі схований шар містить три вузли, H_1 , H_2 , та H_3 , як зображено на Фіг.9. Кожний вузол діє як рівняння регресії, перетворюючи суму зважених вхідних сигналів:

$$H_{i(IN)} = W_{01} + W_{11}X_1 + \dots + W_{n1}X_n$$

де (w_{01}, \dots, w_{n1}) - це вагові коефіцієнти, зв'язані з кожним із вхідних сигналів (x_0, \dots, x_n) , за умови $x_0 = 1$, для вузла схованого шару H_i .

У разі використання сигмоїдальної функції активації для вузлів схованого шару, кожний вузол схованого шару трансформує зазначений вхідний сигнал за допомогою сигмоїдальної функції, такої як, наприклад:

$$H_{i(OUT)} = 1/(1 + e^{-H_{i(IN)}})$$

де $H_{i(OUT)}$ - це вихідний сигнал вузла схованого шару H_i .

Вихідне значення на кожному з вузлів схованого шару множиться на ваговий коефіцієнт його сполучення з вузлом вихідного шару (тобто b_i). Результати таких множень сумуються, внаслідок чого одержується вхідний сигнал для вузлів вихідного шару; таким чином, вхідна величина функції активації вузла вихідного шару визначається як:

$$Y_{IN} = b_0 + b_1 H_{1(OUT)} + b_2 H_{2(OUT)} + b_3 H_{3(OUT)}$$

Прогнозоване або передбачуване значення Y одержується шляхом сигмоїдальної трансформації зазначеної вхідної величини:

$$Y = 1/(1 + e^{-Y_{IN}})$$

Фактичні значення вагових коефіцієнтів сполучення $[(w_{01}, \dots, w_{n1}), (w_{02}, \dots, w_{n2}), (w_{03}, \dots, w_{n3})]$, $[b_0, b_1, b_2, b_3]$ визначаються у процесі навчання. Процес навчання описується у розділі, наведеному нижче. Зверніть увагу на те, що хоча сигмоїдальна функція активації є оптимальною, цей винахід дозволяє використання багатьох інших функцій активації. На Фіг.7(а) зображена функція активації з жорсткими обмеженнями. На Фіг.7 (b) зображена порогова логічна функція активації. На Фіг.7 (с) зображена сигмоїдальна функція активації. Інші функції активації також можуть використовуватися разом з цим винаходом.

Вхідні дані

Нейронна мережа сприймає вхідні дані 407 крізь вхідний шар 405 (Фіг.4). У випадку цього винаходу вхідні величини мають форму даних, одержаних за допомогою певного сенсорного процесу сприймання інформації, а також заданих наперед класифікацій «Out» або «In». Коли ковзне вікно 205 або 505 пересікає край об'єкта, якій необхідно виявити виходячи з даних, одержаних за допомогою певного сенсорного процесу сприймання інформації, значення дисперсії 1001 оптимальної точки навчання стає меншим за значення цієї характеристики в усіх інших точках масиву даних, суміжних з точкою розміщення ковзного вікна 205 на краю об'єкта.

Навчання

Як вже зазначалося раніше, кожне сполучення між вузлами нейронної мережі має зв'язаний з ним ваговий коефіцієнт. Вагові коефіцієнти визначають, який відносний вплив матиме вхідний сигнал на вихідне значення відповідного вузла. Перед початком навчання мережі, для кожного з вагових коефіцієнтів вибираються довільні значення. Вагові коефіцієнти змінюються у міру того, як відбувається процес навчання нейронної мережі. Вагові коефіцієнти змінюються відповідно до закону навчання, пов'язаного з нейронною мережею.

Вагові коефіцієнти, що використовуються нейронною мережею - це регульовані величини, які визначають (для будь-якої заданої конфігурації нейронної мережі) прогнозовані значення класифікації для заданого набору вхідних даних. Для певних завдань нейронні мережі є кращими за звичайні статистичні моделі, тому що нейронні мережі здатні автоматично коригувати значення своїх вагових коефіцієнтів і, таким чином, вони

не вимагають апріорне знання значень вагових коефіцієнтів. Отже, нейронні мережі здатні будувати структуру взаємозв'язків між вхідними та вихідними даними (або модель) шляхом коригування вагових коефіцієнтів, тоді як розробник звичайної статистичної моделі змушений визначати рівняння та задавати фіксовані значення констант(и), що використовуватимуться у цьому(цих) рівнянні(ях).

Коригування вагових коефіцієнтів у нейронній мережі, як правило, називається процесом навчання. Навчання нейронної мережі вимагає, щоб були зібрані навчальні дані 201 (Фіг.2) для використання у процесі навчання. У випадку цього винаходу вони складаються з даних, одержаних за допомогою певного сенсорного процесу сприймання інформації, а також заданих наперед класифікацій «Out» або «In». Потім процес навчання проходить стадії, показані на Фіг.6, та описані нижче. Звертаючись до Фіг.6, слід зазначити, що даний винахід лише спрощується розглянутим конкретним підходом до навчання нейронної мережі, але не залежить від нього. На стадії 600 ваговим коефіцієнтам задаються довільні початкові значення. У процесі переучування нейронної мережі стадія 600 може пропускатися, отже навчання починається з вагових коефіцієнтів, розрахованих для нейронної мережі у попередньому(х) сеансі(ах) навчання. На стадії 601 на нейронну мережу подається набір вхідних даних. Як вже описувалося раніше, ці вхідні сигнали змушують вузли вхідного шару генерувати вихідні сигнали, що подаються на вузли схованого шару, який, у свою чергу, генерує вихідні сигнали, які подаються на вихідний шар, а той, відповідно, генерує необхідні класифікації згідно з даним винаходом. Цей потік інформації від вузлів вхідного шару до вузлів вихідного шару зазвичай називається прямим потоком активації. Прямий потік активації зображений справа на Фіг.3.

Повертаємося знову до Фіг.6. З вхідними даними, які подаються на нейронну мережу на стадії 601, зв'язані потрібні (фактичні або відомі, або вірні) вихідні значення. У даному винаході, це - задані наперед значення класифікації «Out»/«In», хоча у цьому випадку вони практично невідомі. На стадії 603 класифікація, генерована нейронною мережею, порівнюється з заданими наперед значеннями класифікації. Різниця між потрібними вихідними значеннями - тобто, заданими наперед значеннями класифікацій, та класифікацією, генерованою нейронною мережею, називається величиною помилки. Значення помилки потім використовується для коригування вагових коефіцієнтів нейронної мережі, як показано для стадії 605.

Одним з можливих підходів до коригування вагових коефіцієнтів є метод зворотного розповсюдження помилки (також широко відомий як узагальнене дельта-правило). Зворотне розповсюдження помилки - це контрольований спосіб навчання, у якому вихідний сигнал помилки подається назад крізь мережу, змінюючи вагові коефіцієнти сполучень таким чином, щоб мінімізувати помилку. Для зворотного розповсюдження використовується значення помилки, а закон навчання визначає, якою мірою треба коригувати вагові коефіцієнти нейронної мережі. Фактично, помилка між прогнозованим вихідним значенням та бажаним вихідним значенням розповсюджується назад крізь вихідний шар та схований(і) шар(и). Зворотне розповсюдження подає сумарне значення помилки на кожний з вузлів у нейронній мережі і коригує вагові коефіцієнти, пов'язані з вхідними даними на кожному з вузлів, використовуючи значення помилки, асоційоване з даним вузлом. Таким чином, величина помилки розповсюджується у зворотному напрямі крізь нейронну мережу. Звідси і назва «зворотне розповсюдження». Цей зворотний потік передачі помилки зображений зліва на Фіг.3.

Якщо помилка, асоційована з певним вузлом, відома, вагові коефіцієнти цього вузла можна коригувати. Одним з варіантів коригування вагових коефіцієнтів даного вузла може бути такий:

$$W_{\text{new}} = W_{\text{old}} + \beta EX$$

де E - це сигнал помилки, пов'язаний з вузлом, X відображає вхідні сигнали (у формі вектора), W_{old} - це поточні значення вагових коефіцієнтів (представлені у формі вектора), W_{new} - значення вагових коефіцієнтів після їх коригування, а β - константа або швидкість навчання. β можна також розуміти як розмір кроків переміщення вздовж кривої помилок. Даний винахід допускає також використання інших варіантів цього способу. Наприклад, такий можливий варіант:

$$W_{\text{new}} = W_{\text{old}} + \beta EX + \alpha (W_{\text{new}} - W_{\text{old}})_{\text{prev}}$$

включає член імпульсу, $\alpha(W_{\text{new}} - W_{\text{old}})_{\text{prev}}$, де α - константа, що множиться на величину зміни вагового коефіцієнта у порівнянні з попередньою конфігурацією вхідних даних.

Згідно з методом зворотного розповсюдження помилки, який є одним із прикладів способів навчання, що можуть використовуватися у нейронній мережі, значення помилки на кожному з вузлів схованого шару обчислюються шляхом підсумовування помилок на кожному з вузлів вихідного шару, помножених на відповідний ваговий коефіцієнт сполучення між схованим вузлом схованого шару та відповідним вихідним вузлом вихідного шару. Ця оцінка помилки по кожному з вузлів схованого шару потім використовується описаним вище чином для коригування вагових коефіцієнтів між вхідним шаром та схованим шаром.

Отже, можна бачити, що помилка між вихідними даними та вхідними навчальними даними розповсюджується у зворотному напрямі крізь мережу з коригуванням вагових коефіцієнтів таким чином, щоби зменшити цю помилку. Процес ітераційно повторюється для набору навчальних даних 201 доти, доки навчання не завершується. Як показано для стадії 607, для того щоб визначити, завершився чи не завершився процес навчання, використовується тестовий набір даних. Як правило, цей тест просто перевіряє, чи стала помилка навчання меншою за певне порогове значення після певної кількості попередніх ітерацій процесу навчання, або він просто перериває навчання після певної кількості ітерацій.

Оптимальною методикою є використання тестового набору даних 202 та оцінка помилки, яка генерується тестовими даними. Тестові дані формуються таким чином, щоб вони не були взаємно сумісними з даними, які використовуються для навчання. В оптимальному варіанті втілення цього винаходу нейронній мережі дозволяється вчитися доти, доки не досягається оптимальна точка припинення навчання. Оптимальною точкою припинення навчання є такий момент процесу навчання нейронної мережі, коли дисперсія 1001 класифікаційних значень, генерованих нейронною мережею, досягає мінімуму по відношенню до відомих результатів для тестового набору даних 202, сформованого з даних певного сенсорного процесу сприймання інформації, та заданих наперед класифікацій «Out»/«In». Зверніть увагу на те, що коли тестовий набір даних 202 використовується для визначення моменту завершення навчання, вагові коефіцієнти не коригуються в

результаті подачі тестових даних на нейронну мережу. Це означає, що тестові дані не використовуються для навчання нейронної мережі.

Стисло кажучи, для навчання нової конфігурації нейронної мережі, як правило, ваговим коефіцієнтам спочатку задаються довільні значення (стадія 600). У ході навчання на стадії 601 нейронна мережа використовує подані на неї вхідні дані для генерування прогнозованих вихідних значень, як показано вище. Ці вихідні значення використовуються у комбінації з навчальними вхідними даними для того, щоб одержати величину помилки, стадія 603. Величина помилки - це різниця між вихідними даними з вихідних вузлів та цільовими або фактичними даними, які, у випадку цього винаходу, складаються з заданих наперед класифікацій «Out»/«In». Потім ці величини помилки розповсюджуються у зворотному напрямку крізь вихідний(і) вузол(вузли) та використовуються для коригування вагових коефіцієнтів вузлів згідно з функцією активації, заданою для цих вузлів, стадія 605. Виконується обчислення дисперсії 1001 між класифікаційними значеннями, генерованими нейронною мережею для тестових даних 202, та класифікаційними значеннями, заданими наперед для тестових даних 202 (стадія 609). Тест на дисперсію 1001 використовується для визначення того, чи завершено навчання, чи його потрібно продовжити (стадія 607).

Зверніть увагу на те, що хоча оптимальний варіант втілення цього винаходу був описаний по відношенню до основного алгоритму розповсюдження помилки у зворотному напрямі, у цьому винаході можуть також використовуватися інші варіанти алгоритмів розповсюдження у зворотному напрямі. Також можуть бути використані інші закони навчання. У методі закріплюваного навчання глобальний сигнал закріплювання подається на усі вузли нейтральної мережі. Потім вузли коригують свої вагові коефіцієнти на основі даного сигналу закріплювання. Це у корені відрізняється від методики розповсюдження у зворотному напрямку, яка фактично намагається сформувати сигнал помилки на виході кожного з нейронів мережі. У методі закріплюваного навчання існує лише один сигнал помилки, який подається на усі вузли.

Навчальні і тестові дані

Нейронна мережа навчається шляхом багаторазової подачі на неї навчальних даних 201. Згідно зі Фіг.5 кожний набір навчальних даних 501 містить сукупність елементів масиву даних 503, одержаних шляхом певного сенсорного процесу сприймання інформації, та заданих наперед класифікаційних значень «Out» або «In». Тестовий набір даних 202 є ідентичним навчальному набору 201 за своєю структурою. Але тестовий набір даних 202 суттєво відрізняється від навчального набору 201 тим, що не містить жодного з тих елементів даних, які є у навчальному наборі.

У випадку цього винаходу один з наборів даних використовується як навчальний, а два інших суміжних та вишикуваних у лінію набори даних утворюють тестовий набір 202. У цьому винаході тестовий набір даних 202 сконфігурований таким чином, що по кожну сторону від лінії навчального набору даних знаходиться по одній послідовності елементів тестових даних. Мета такої конфігурації буде далі розкрита.

Попередня обробка даних

Функція попередньої обробки даних 107 зображена на Фіг.1. Попередня обробка даних може проводитися, коли вхідні дані подаються на нейронну мережу; або вхідні дані можуть проходити попередню обробку та зберігатися як попередньо оброблені величини у наборі вхідних даних. Якщо попередня обробка даних застосовується, вона включати одну або декілька стадій. Наприклад, було виявлено, що класичний метод розповсюдження помилки у зворотному напрямку краще працює, коли вхідні дані нормовані або в інтервалі $[-1,1]$, або в інтервалі $[0,1]$. Зверніть увагу на те, що нормування проводиться по кожному з множників даних. Наприклад, у випадку сейсмічних даних, амплітуди по кожному періоду проходження хвилі в обох напрямках нормуються як вектор. Стадія нормування може також поєднуватися з іншими стадіями - такими як знаходження натуральних логарифмів вхідних даних. Таким чином, попередня обробка даних може складатися із знаходження натуральних логарифмів кожного з вхідних сигналів та нормування вхідних сигналів в межах певного інтервалу. Логарифмічна шкала дозволяє стиснути великі значення величин до набагато менших. Коли нейронна мережа містить вузли з сигмоїдальною функцією активації, кращі результати досягаються, якщо дані нормуються у межах інтервалу $[0.2, 0.8]$. Нормування в інтервалі $[0.2, 0.8]$ дозволяє використовувати середню частину сигмоїдальної функції активації. Для попередньої обробки вхідних значень можна використовувати й інші функції.

Розрахунок дисперсії у порівнянні з тестовими даними

Згідно зі Фіг.6 та 10, обчислення значення дисперсії (609) класифікаційних значень, генерованих нейронною мережею для тестового набору даних 202, по відношенню до заданих наперед класифікаційних значень даних цього набору (як показано для стадії 609 на Фіг.6) і використання цієї дисперсії для визначення оптимальної точки припинення подальшого навчання спрощує даний винахід, але не є для нього обов'язковим. Цей допоміжний варіант, який є елементом бажаного варіанту втілення даного винаходу, описується у цьому розділі. Після того як вагові коефіцієнти скориговані, як показано для стадії 605, на нейронну мережу подається тестовий набір даних 202. Далі розраховується дисперсія 1001, що є дисперсією між класифікаційними значеннями, генерованими нейронною мережею для тестового набору 202, та заданими наперед класифікаційними значеннями для тестового набору 202. Потім ця дисперсія використовується для визначення того, чи досяг процес навчання оптимального відгуку даної нейронної мережі (стадія 607), і в тому випадку, коли оптимальний відгук досягнутий, навчання припиняється.

Існують два питання, пов'язані з досягненням оптимального результату: 1) з чого складається дисперсія, і 2) як визначити, що досягнута оптимальна дисперсія. На Фіг.10 зображені дві кривих, обидві з яких є функціями кількості ітерацій процесу навчання нейронної мережі. Одна з кривих є залежністю середньоквадратичної помилки 1003, яка визначається для навчального набору даних 201, а інша - залежністю дисперсії 1001, яка визначається для тестового набору даних 202.

Метою нейронної мережі, коли відбувається процес її навчання, є мінімізація середньоквадратичної помилки 1003 шляхом коригування вагових коефіцієнтів нейронної мережі після кожної ітерації. В результаті, з кожною наступною ітерацією нейронна мережа узгоджується з усе більшим та більшим ступенем точності з набором навчальних даних, тоді як крива середньоквадратичної помилки 1003 асимптотично прагне

наблизитися до нуля. Таким чином, нейронна мережа може пристосуватися до заданої конфігурації даних з будь-яким довільно вибраним ступенем точності. Проте, це не є остаточною метою використання методу нейронної мережі для одержання класифікацій. Остаточною метою є створення такої нейронної мережі, яка здатна узагальнювати інші набори даних, що подаються на неї. Отже, існує такий момент ітераційного процесу, коли нейронна мережа вже вивчила основні конфігурації навчальних даних і далі починає запам'ятовувати основні конфігурації даних разом з шумами, які вони можуть містити.

Цієї проблеми надмірного пристосування або надмірного навчання можна уникнути, якщо нейронна система навчається, використовуючи навчальний набір даних 201, але оцінює свою здатність до узагальнення на іншому наборі даних, який називається тестовим набором даних 202. Це досягається шляхом обчислення дисперсії 1001 між класифікаційними значеннями, генерованими нейронною мережею для тестового набору даних 202, та заданими наперед класифікаційними значеннями для цього тестового набору.

Дисперсія може бути будь-якою функцією, яку розробник системи вважатиме найбільш придатною для поставленої перед ним проблеми. Наприклад, у разі класифікаційних проблем, таких як оконтурювання просторово залежних об'єктів, дисперсія 1001 може бути середньоквадратичною помилкою для тестового набору даних 202, перевіркою за критерієм χ^2 -квадрат або просто кількістю невірно визначених відгуків. Спеціалісти у даній галузі швидко зрозуміють, що з таким же успіхом можна використовувати багато різних способів обчислення дисперсії, не відхиляючись від справжньої суті та обсягу цього винаходу. Стадія 609 на Фіг.6 відображає точку ітераційного процесу, у якій розраховується дисперсія.

Ітерація, у якій дисперсія 1001 досягає мінімального значення, є оптимальною точкою припинення навчання 1005 для будь-якого заданого набору даних 202. У цій точці нейронна мережа закінчує вивчати основну конфігурацію(i) даних навчального набору і починає надмірне пристосування або надмірне запам'ятовування даних. Так як і саму дисперсію можна обчислювати за допомогою різних способів, оптимальну точку припинення навчання також можна розраховувати багатьма способами. Це - точка, у якій дисперсія у подальшому ході навчання перестає зменшуватися і замість того починає зростати. Наприклад, цю точку перетину можна визначити просто, спостерігаючи, щоб дисперсія не утворила нового мінімуму в межах певної заданої кількості ітерацій, або складніше - шляхом розрахунку поточної лінійної регресії для певної кількості минулих ітерацій та визначення того, коли тангенс кута нахилу лінії стає додатним. Спеціалісти у даній галузі швидко зможуть запропонувати багато інших способів для визначення мінімуму, не відхиляючись від справжньої суті та обсягу цього винаходу. Стадія 609, зображена на Фіг.6, це той момент ітераційного процесу, коли проводяться розрахунки для визначення мінімуму.

На практиці у пам'яті можуть зберігатися значення вагових коефіцієнтів нейронної мережі для відповідної кількості минулих ітерацій. Ці значення вагових коефіцієнтів позначаються номерами тих ітерацій, у яких вони були досягнуті. Після того як буде визначено, що досягнута точка перетину, номер ітерації з мінімальною величиною дисперсії використовується для збереження у пам'яті оптимальних значень вагових коефіцієнтів нейронної мережі.

Оконтурювання просторово залежних об'єктів

У поданій паралельно з цією заявкою заявці на патенті США номер 08/974,122 «Оптимальне припинення навчання у нейронних мережах» розкривається спосіб оптимального припинення процесу навчання. Це те, що раніше тривалий час було проблемою для використання нейронних мереж. Проте, аналогічна проблема продовжує існувати. Вона полягає у тому, як визначити оптимальну кількість вузлів, тобто, архітектуру нейронної мережі, та яку(i) функцію(ii) застосувати для конкретної архітектури нейронної мережі. Отже однією з цілей даного винаходу є розкриття того, як визначити належну кількість вузлів та належну функцію активації для використання у нейронній мережі до початку загального процесу оконтурювання просторово залежних об'єктів, зображеного на Фіг.11.

Кількість вузлів, необхідна для оптимального вирішення конкретної проблеми методом нейронної мережі, у першу чергу, залежить від загальної структури проблеми - наприклад, від кількості змінних, кількості спостережень, кількості вихідних вузлів тощо. Фактичні величини даних не виявляють значного впливу на необхідну кількість вузлів. Ще менше значення даних впливають на необхідну кількість ітерацій процесу навчання. Отже першою стадією 1101 процесу оконтурювання просторово залежних об'єктів буде визначення оптимальної кількості вузлів для мережі. Цей процес завершується формуванням ковзного вікна 205, розміщенням його у певній області даних, яка вважається відповідною (наприклад, дивися Фіг.12), а потім тимчасовим та послідовним перетворенням тієї частини даних, яка охоплюється ковзним вікном 1206. У випадку сейсмічних даних, які використовуються у цьому прикладі, можна уявити, що верхній лівий кут сейсмічного плану, як показано на Фіг.12, фактично знаходиться за межами нафтогазової зони і є хорошим місцем для визначення необхідної кількості вузлів. Далі, якщо продовжувати розгляд прикладу сейсмічних даних, декілька конкретних амплітуд можуть бути тимчасово змінені до одного і того ж значення в усіх сейсмограмах загальної глибинної точки (як показано на Фіг.13), які припадають на частину «In» ковзного вікна. Причина завдання тимчасових значень полягає у тому, щоб не зробити ці значення занадто відмінними одне від одного, оскільки переслідуваною метою є не негайне зменшення дисперсії до нуля, а скоріше - спостереження за тим, як вона спадає. Потім нейронна мережа навчається до моменту досягнення оптимальної точки припинення навчання на ряді різних послідовних кількостей вузлів. Для кожної кількості вузлів зберігається у пам'яті та відслідковується дисперсія на тестовому наборі даних 202, а після того як стає зрозумілим, що конкретна кількість вузлів дає мінімальне значення дисперсії, навчання припиняється. Потім та кількість вузлів, для якої був досягнутий мінімум дисперсії, використовується у процесі оконтурювання.

Як показано для стадії 1102 на Фіг.11, аналогічний процес використовується для визначення оптимальної функції активації, приклади якої наведені на Фіг.7. Функція активації діє по-різному на різні типи даних, тобто те, як змінюються величини - плавно чи зі сплесками, може впливати на результати використання різних активаційних функцій. Отже, після визначення оптимальної кількості вузлів, тобто архітектури мережі, та до відновлення вихідного стану даних, на нерухомому ковзному вікні 1206 з оптимальною кількістю вузлів перевіряються різні активаційні функції. Для кожної перевіреної активаційної функції зберігається у пам'яті та

відслідковується дисперсія на тестовому наборі даних 202. Нарешті, відновлюються початкові значення даних, а активаційна функція, яка дала мінімальне значення дисперсії, береться як функція активації для усього процесу оконтурювання.

Коли існують часткові відомості або, навіть, коли можливі інтуїтивні припущення щодо приблизного оконтурювання, такі відомості, інтуїтивні припущення або здогадки можна використовувати для прискорення процесу оконтурювання. Отже, ще однією метою даного винаходу є розкриття того, як можна включити до процесу такі неповні знання. В ілюстративному випадку сейсмічних даних, такі відомості можуть бути одержані з аеромагнітних профілів або гравітаційних досліджень, або навіть з досвіду та оцінок інтерпретаторів сейсмічних даних або геологів. Наприклад, у випадку сейсмічних даних, зображених на Фіг.12, загальноживаною практикою є початок сейсмічних вибухів за межами можливих зон залягання нафти та/або газу та розповсюдження їх вздовж ліній, що пересікають зону, яка представляє інтерес. Видається цілком ймовірним, що сейсмограми загальної глибинної точки у куту сейсмічного плану будуть знаходитися за межами можливих зон залягання нафти та/або газу, тоді як загальні глибинні точки всередині можливих зон залягання нафти та/або газу знаходитимуться посередині сейсмічного плану. У разі розпізнавання людського обличчя - складної та важливої просторово-залежної задачі нейронних мереж - як правило, людське обличчя представляється на однорідному фоні. Таким чином, у разі розпізнавання людського обличчя ми можемо сподіватися знайти людське обличчя всередині даних, тоді як фон можна розраховувати знайти у кутах. Ми можемо використовувати часткові відомості, інтуїтивні припущення або здогадки такого типу для прискорення процесу оконтурювання.

Отже, третьою стадією 1103 процесу оконтурювання просторово залежних об'єктів (зображеному на Фіг.11) буде включення до процесу часткових знань, інтуїції або здогадок. Звертаючись до Фіг.14, на якій продовжується розгляд прикладу сейсмічного плану, представленого на Фіг.12, ми бачимо, що ковзне вікно 1206 Фіг.12 розщеплене на Фіг.14 на дві частини - 1401 та 1402. Частина «Out» розщепленого ковзного вікна 1401 зроблена нерухомою у куту сейсмічного плану даних, тоді як частина «In» 1402, який дозволений ковзний рух, спочатку знаходиться всередині сейсмічного плану 1400. Потім проводиться процес навчання нейронної мережі, до якої входять обидві частини ковзного вікна, для знаходження оптимальної точки з використанням кількості вузлів та функції активації, визначених на стадіях 1101 та 1102 процесу оконтурювання. Швидко сходження до мінімальної дисперсії, що має малу величину, вказує на те, що існує скупчення, зона або кластер певного типу. Якщо не спостерігається швидкої збіжності нейронної мережі до малого значення дисперсії, то може бути бажаним змістити ковзне вікно «In» до іншої позиції та повторити процес. Якщо спосіб, що розкривається цим винаходом, використовується для оконтурювання основного об'єкта, повне оконтурювання об'єкта часто може бути досягнутим після навчання з використанням часткових відомостей інтуїтивних припущень або здогадок. Таким чином, на Фіг.11 у блоці 1107 приймається рішення щодо того, завершений чи не завершений процес оконтурювання після закінчення процесу навчання. Якщо «так», то процес переходить до блоку 1106, який розглядається нижче. З іншого боку, якщо оконтурювання не завершено після закінчення навчання, процес переходить до блоку 1104.

Інформація, пов'язана з процесом, за деяких обставин може бути одержана як результат певного засобу формування конфігурації ковзного вікна. Якщо одна сторона тестового набору даних 202 збігається, а друга - ні, то можна зробити висновок, що частина «In» ковзного вікна знаходиться на краю скупчення, як показано для позиції 505. Отже, переміщення частини «In» ковзного вікна 502 у напрямку тієї сторони тестового набору, що збігається, тобто вниз (Фіг.5), скоріше за все викличе появу збіжності для обох сторін ковзного вікна. Це - та причина, з якої тестовий набір даних розташовується симетрично по обидві сторони навчального набору даних. Таким чином, один з аспектів мети даного винаходу, а саме - визначення напрямку, в якому знаходиться об'єкт, скупчення або кластер, коли ковзне вікно, що розкривається у цьому винаході, розміщене на краю або у куту об'єкта, скупчення або кластера, досягається для обох сторін. Після того, як досягнута урівноважена збіжність, повний масив даних 509 знову пропускається крізь нейронну мережу з остаточними значеннями вагових коефіцієнтів з метою повного оконтурювання об'єкта, скупчення або кластера.

Дуже часто немає ні відомостей, ні інтуїтивних припущень щодо місцезнаходження просторово залежних об'єктів. Фактично, часто важливо знати, чи є хоча б можливість того, що такі об'єкти існують у межах заданого набору даних. Останнє є особливо важливим і цінним для аналізу сейсмічних даних. Отже, ще однією метою цього винаходу є забезпечення системи, способу та процесу для визначення того, чи існують взагалі помітні об'єкти серед даних, зібраних за допомогою певного сенсорного процесу. Наприклад, чи взагалі можливо оконтурити зони, характерні для колекторів вулководнів, у межах площі, що охоплюється даною сейсмічною розвідкою. Ця мета досягається як тоді, коли є попередні відомості щодо існування зазначених оконтурень, скупчень, зон чи кластерів, так і тоді, коли таких попередніх відомостей немає.

Це досягається на стадії 1104, зображеній на Фіг.11, шляхом переміщення ковзного вікна 1206 по усьому масиву даних. Ковзне вікно не розщеплене, і у загальному випадку починає рухатися з будь-якого кута, як показано на Фіг.12. Процес навчання ведеться до оптимальної точки, як і раніше, а після досягнення збіжності набір даних переміщується на одну точку уперед. Тобто, перші точки випадають з кожної з трьох ліній даних, з яких складається ілюстративне ковзне вікно 205. Далі перші три точки «In» стають точками «Out». І нарешті, три нові точки «In» додаються до ковзного вікна. Потім процес навчання нейронної мережі починається знову і закінчується новим значенням дисперсії в оптимальній точці припинення навчання. Доти, доки ковзне вікно знаходитиметься повністю за межами зони, скупчення або кластера, значення дисперсії залишатимуться високими та близькими до постійної величини для усіх позицій ковзного вікна. Як тільки ковзне вікно натрапляє на зону, скупчення або кластер, які необхідно виявити, величина дисперсії починає падати і досягає мінімуму тоді, коли центр ковзного вікна знаходиться на краю ділянки, скупчення або кластера, які необхідно виявити. Як і у попередньому випадку, якщо досягається значна та урівноважена збіжність, повний масив даних 509 знову пропускається крізь нейронну мережу з остаточними значеннями вагових коефіцієнтів з метою повного оконтурювання об'єкта, скупчення або кластера. Якщо значна збіжність не досягається, то існування скупчень, зон або кластерів мало ймовірне.

У багатьох випадках просторово залежних об'єктів оконтурювання тільки основного об'єкта недостатньо. Вимагається також оконтурювання підобластей з різними властивостями. Наприклад, у випадку сейсмічних даних та вуглеводневих скупчень, також значний інтерес і цінність представляє відокремлення газової шапки від водонафтового контакту (OWC /oil water contact/) нафтогазового родовища, як показано на Фіг.15, або відокремлення зон з різною пористістю, проникністю чи продуктивністю на основі сейсмічних даних. Отже, ще однією метою даного винаходу є забезпечення системи, способу та процесу для відокремлення різних підоб'єктів, підобластей або субкластерів, що можуть існувати в межах заданого набору даних, одержаних за допомогою певного сенсорного процесу сприймання інформації.

Ця мета може бути досягнута на стадії 1105, зображеній на Фіг.11, навіть коли немає попередніх відомостей щодо існування зазначених вище суб-оконтурень, субскупчень, підобластей або субкластерів. Припускаючи, що повний основний об'єкт вже оконтурений, розміщуємо повне ковзне вікно 1501 на точці, що знаходиться на краю оконтуреного об'єкта, на одній лінії з очікуваним місцезнаходженням підоб'єкта. Проте, цього разу ковзне вікно знаходиться повністю всередині основного об'єкта, а частина «Out» ковзного вікна є суміжною з краєм основного об'єкта. Ковзне вікно проходить процес навчання до досягнення оптимальної точки, а потім переміщується вперед, згідно з викладеним вище. Значення дисперсії в оптимальній точці відслідковуються з метою визначення такої позиції вікна, для якої дисперсія мінімальна. Після знаходження мінімального значення дисперсії точки повного масиву даних 509 або певної підмножини цього масиву можуть бути пропущені крізь мережу з остаточними значеннями вагових коефіцієнтів з метою оконтурювання підоб'єкта. В іншому варіанті, можливе систематичне переміщення ковзного вікна по усій області існування основного об'єкта. Можна очікувати, що при оконтурюванні підоб'єктів значення дисперсії буде більшим, а мінімум - не таким виразним, як у випадку оконтурювання повного основного об'єкта. Наприклад, у разі відокремлення газової шапки 1502 від водонафтового контакту (OWC /oil water contact/) 1503, можна сподіватися, що значення дисперсії в оптимальній точці у випадку розміщення центру ковзного вікна на краю газової шапки буде більшим, ніж у разі, коли частина «Out» ковзного вікна повністю знаходиться за межами скупчень нафти і газу, а частина «In» ковзного вікна розміщена достатньо точно по центру комбінованого нафтогазового скупчення. На Фіг.15 ковзне вікно знаходиться на краю водонафтового контакту за одну точку від попадання центру ковзного вікна на край газової шапки, що означає, що для досягнення краю газової шапки треба перемістити центр ковзного вікна праворуч.

Тривалою проблемою у використанні нейронних мереж була можливість визначення ступеня точності, якого досягає певний прогноз або певна класифікація. Отже, ще однією метою даного винаходу є розкриття способу внутрішнього підтвердження точності оконтурень, тобто визначення ступеня точності оконтурювання, зробленого за допомогою системи, способу та процесу, які розкриваються у даному винаході.

Ця мета може бути досягнута на стадії 1106, зображеній на Фіг.11, шляхом оконтурювання спочатку усіх значень «Out» та «In» класифікації, яка перевіряється, стадія процесу 1103 або 1104. Потім з повного масиву даних оконтурювання довільно береться вибірка величин для навчального набору відповідного розміру - такого, як той, що використовується у ковзному вікні. Далі йде процес навчання навчального набору даних до досягнення оптимальної точки, а значення вагових коефіцієнтів, одержані в результаті навчання, використовуються для перекласифікації повного масиву даних 509, що відповідає класифікації, яка перевіряється, за винятком довільно обраного набору навчальних даних. Потім реєструється розходження з початковою класифікацією. Знову довільно береться нова вибірка навчальних даних та проходить процес навчання до досягнення оптимальної точки. Ще раз здійснюється перекласифікація повного масиву значень «Out» та «In» і знову реєструється розходження з початковою класифікацією. Така процедура довільної вибірки даних, навчання та перекласифікації повторюється як мінімум тридцять (30) разів. Далі використовуються стандартні статистичні методи, добре відомі спеціалістам відповідної галузі, для обчислення середнього значення та довірчого інтервалу дисперсії нейронної мережі для даної конкретної класифікації, яка перевіряється. Основні об'єкти, такі як нафтові та нафтогазові або газові родовища, можуть давати нульові значення дисперсії, тоді як підоб'єкти, такі як зони з різною пористістю чи проникністю, даватимуть ненульові значення дисперсії в межах вузького довірчого інтервалу. Це спостерігається тому, що сейсмічні дані перекривають різні зони з відмінною пористістю, проникністю або продуктивністю. У вміщеному нижче розділі, де розглядається оконтурювання вуглеводневих скупчень, описаний ще один новий аспект - спосіб визначення ступеня точності, з яким одержаний(а) певний прогноз або певна класифікація - який відповідними пунктами формули включається до цього винаходу.

Існує цілий ряд галузей, де можуть знайти широке застосування система, способи та процес, які розкриваються цим винаходом. Неповний перелік зразків таких галузей був наведений вище у розділі «Передісторія винаходу». Отже, ще одна мета цього винаходу - показати, як загальні концепції, які розкриваються у даному винаході, можуть застосовуватися у різних галузях, проектах та фізичних втіленнях винаходу. Крім того, конкретні характеристики різних сенсорних вхідних даних можуть створювати практично однакові задачі для нейронних мереж, а саме задачі оконтурювання просторово залежних об'єктів.

Хоча концепції, що розкриваються у цьому винаході, призначені для підвищення ефективності процесу, загальний процес як і раніше вимагає чимало обчислень. Отже, ще одна мета цього винаходу - показати, як загальні концепції, що розкриваються у даному винаході, можуть втілюватися паралельно на різних комп'ютерах та можуть вбудовуватися безпосередньо до апаратних засобів для прискорення процесу обробки даних. Паралельна обробка даних за концепціями, що розкриваються цим винаходом, може здійснюватися різними шляхами. Наприклад, для проходження масиву даних з метою визначення місцезнаходження основного об'єкта (так, як у випадку знаходження вуглеводневого скупчення за сейсмічними даними) можна використовувати декілька комп'ютерів. У цьому випадку, процес навчання для однієї позиції ковзного вікна проводиться паралельно на кожному з комп'ютерів; таким чином, ковзне вікно переміщується уперед паралельно на ряді комп'ютерів, на кожному з яких одержується паралельне рішення задачі. У кінці кожного паралельного рішення значення дисперсій об'єднуються в один файл для того, щоб вести спостереження за їх змінами. Це дозволяє швидко досягати узгодження значень дисперсії для всієї мережі. Ще одним прикладом

використання паралельної обробки даних у разі застосування цього винаходу може бути процес визначення відповідної кількості вузлів. У цьому випадку, на кожному з комп'ютерів у процесі навчання використовуються різні кількості вузлів, а одержані дисперсії збираються докупи для оцінки наприкінці кожного паралельного розрахунку. І в цьому разі таке комбінування значень дисперсії може бути швидко досягнуте для всієї мережі. Використовуючи концепції, що розкриваються цим винаходом, можна знайти й інші варіанти практичного втілення паралельної обробки даних; відповідно, передбачається, що додана формула винаходу охоплює усі такі варіанти його застосування, які відповідають справжній суті та обсягу цього винаходу.

Часто розпізнавання просторово залежних об'єктів необхідно проводити у режимі реального часу. Наприклад, у випадку сейсмічних даних це може бути особливо цінним щодо економії дорогого часу одержання сейсмічних даних. Отже, ще одна мета цього винаходу - показати, як концепції, що розкриваються у даному винаході, можуть втілюватися для потреб використання у реальному часі. Це може бути досягнуте, у випадку одержання сейсмічних даних, шляхом проведення довгого ряду вибухів, з одночасною обробкою сейсмограм окремих вибухів вздовж одномірної лінії з використанням описаної вище методики ковзного вікна. Коли оконтурювання об'єкта вздовж одномірної лінії закінчене, можна розпочати побудову карти за даними сейсморозвідки в області, перпендикулярній до одномірного об'єкта. Для цього може використовуватися двомірне або тримірне сейсмічного профілювання та обробка даних. Такий підхід дозволяє здійснити точне оконтурювання вуглеводневих скупчень з меншими затратами часу та коштів. Цей підхід може також бути застосований і до сейсмічних даних вібросейсу (генератора безперервних коливань регульованої частоти). Такий же самий підхід може застосовуватися до гідроакустичних даних, для визначення місцезнаходження затопленого об'єкта - наприклад, такого як потоплений літак. Спеціалісти у відповідних галузях швидко зможуть знайти багато інших прикладів застосування концепції цього винаходу у реальному часі; отже відповідно, передбачається, що додана формула винаходу охоплює усі такі варіанти його застосування, які відповідають справжній суті та обсягу цього винаходу.

І у разі використання концепцій цього винаходу для сенсорного сприймання даних у реальному часі, описаного вище, і у разі їх використання для статистичної обробки сенсорних даних, процес можна прискорити шляхом вбудовування функції нейтронної мережі безпосередньо до апаратних засобів. Отже, даний винахід припускає, що концепції, які розкриваються цим винаходом, можуть використовуватися у сполученні з різними конфігураціями апаратних засобів. Фактично, чіпи інтегральних схем нейронних мереж вже існують у продажу і можуть бути сконфігуровані таким чином, щоб втілювати концепції цього винаходу. Відповідно, передбачається, що додана формула винаходу охоплює усі такі варіанти його застосування, які відповідають справжній суті та обсягу цього винаходу.

Ще однією метою цього винаходу є забезпечення системи, способу та процесу для виявлення та оконтурювання вуглеводневих скупчень безпосередньо з даних сейсмічної розвідки. Опис того, як можна використати концепції цього винаходу у його експериментальному застосуванні для оконтурювання газової шапки на нафтогазовому родовищі, наведений як один із численних прикладів варіантів втілення даного винаходу.

Для забезпечення нейронної мережі - основи застосування даного винаходу - в описаному нижче ілюстративному експериментальному варіанті втілення даного винаходу, може бути використана програма «Enterprise Miner», розроблена «SAS Institute, Inc.». Першою задачею є визначення даних, які будуть використані для аналізу, та їх пересилка з формату SEG-Y до наборів даних формату SAS. Використовуються тримірні сейсмічні дані від вибухів динаміту, одержані з приймачів, розташованих з інтервалом двадцять п'ять метрів (25м). У наведеному нижче прикладі використовується згортка 72 трас на одну сейсмограму загальної глибинної точки (Фіг.13). Повний час пробігу до фундаменту та назад складає 1,2 секунди, а інтервал замірів - 2 мілісекунди.

В оптимальному варіанті втілення цього винаходу до уваги беруться повністю усі умови відкладання порід. Це робиться для того, щоб враховувати в аналізі не лише безпосередньо вуглеводневі скупчення, а також такі характеристики, як пастки, шляхи міграції від нафтоматеринських порід та підстильні басейни. В ілюстративному варіанті втілення цього винаходу використовувалися усі амплітуди сигналів від поверхневого шару до фундаменту, і нейронній мережі дозволялося визначити де зупиняється сейсмічна хвиля. Нейронна мережа це робила приблизно за 90мсек. Точка, де зупиняється поверхнева сейсмічна хвиля, визначається шляхом використання ковзного вікна у вертикальному напрямку, замість горизонтального як у прикладах, наведених вище. Оконтурювання вуглеводневого скупчення спочатку виконується з використанням усіх амплітуд від поверхневого шару до фундаменту. Потім невелика кількість амплітуд (25 у прикладі, який розглядається) включається до вертикального ковзного вікна, яке починає рухатися від поверхні та переміщається кожного разу вниз на одну амплітуду доти, доки результати, одержані від 25 амплітуд, не починають підсилювати інтенсивність сигналу функції оконтурювання вуглеводневого скупчення, тобто, тільки 25 амплітуд починають давати позитивний внесок до роздільної здатності на тестовому наборі даних. Це - точка, де поверхнева сейсмічна хвиля вже більше немає домінуючого впливу. Аналогічний процес проводиться під колектором вуглеводнів для визначення точки, в якій умови відкладання порід перестають впливати на оконтурювання вуглеводневого скупчення. Потім амплітуди вище та нижче цих точок відкидаються у подальших розрахунках, таким чином, посилюючи функцію розпізнавання на вуглеводневому скупченні.

У прикладі, який розглядається, використовувалися попередньо зведені у пучок траси з нормальним приростом. Хоча визначення трас безпосередньо з сейсмічних записів, зроблених на території родовища, та їх обробка з одержанням сейсмограм загальної глибинної точки є оптимальним рівнем обробки даних для цього винаходу, точні результати можна одержати з використанням багатьох інших рівнів обробки даних. Даний винахід припускає, що спеціалісти галузі будуть використовувати різні форми відображення даних та різні рівні їх обробки. Відповідно, передбачається, що додана формула винаходу охоплює усі такі форми відображення даних та рівні їх обробки, які відповідають справжній суті та обсягу цього винаходу.

Кожна траса у кожній сейсмограмі загальної глибинної точки класифікується як «In» (1) або «Out» (0), і

кожна сейсмограма також класифікується як «In» або «Out». Таким чином, у прикладі, що розглядається, де кількість трас у збірці становить 72, кожна з 72 трас (або спостережень) сейсмограми загальної глибинної точки класифікується як «In» або як «Out». Найкращі результати від методу нейронної мережі, як правило, одержуються тоді, коли кількість спостережень, які використовуються, у 1,5-2 рази більше за кількість змінних - тобто, у випадку сейсмічних даних, йдеться про кількість усіх амплітуд плюс декількох змінних збірної точки сейсмічних трас. Отже, у прикладі, що розглядається, коли повний час пробігу (TWT /two-way time/) складає 1,2 секунди, а інтервал між вибірками даних - 2 мілісекунди, вимагається приблизно від 900 до 1200 спостережень. За умови 72 трас на одну сейсмограму загальної глибинної точки, для одержання точного рішення у прикладі, який розглядається, достатньо буде 13-17 сейсмограм загальної глибинної точки. Крім амплітуд, у прикладі, що розглядається, використовуються зміщення та статичні змінні збірної точки сейсмічних трас. Проте, точні результати можуть давати різні комбінації змінних збірної точки сейсмічних трас та амплітуд; отже, передбачається, що додана формула винаходу охоплює усі такі комбінації змінних, які відповідають справжній суті та обсягу цього винаходу.

Попереднє визначення відповідної кількості вузлів 1101 та функції активації (1102 та Фіг.7) було проведено згідно з предметом даного винаходу. Крім того, навчання з метою визначення відповідної кількості вузлів було припинене приблизно через 25 ітерацій після точки, яка пізніше була визначена як оптимальна у реальних класифікаційних обчисленнях. Оскільки існували часткові відомості про газову шапку, усі траси восьми (8) сейсмограм загальної глибинної точки на периферії сейсмічного плану були класифіковані як «Out», а усі траси восьми (8) сейсмограм загальної глибинної точки, що містилися у центрі плану, були класифіковані як «In». Ці дані були використані для створення навчального набору даних 201 у розщепленому ковзному вікні 1401 та 1402. Тестовий набір даних 202 був сформований аналогічно згідно з предметом даного винаходу. Для розщепленого вікна проводилися обчислення до досягнення оптимальної точки навчання, після чого були класифіковані усі інші точки повного масиву даних 509. Стадія підтвердження точності обчислень показала, що усі сейсмограми загальної глибинної точки у повному масиві даних 509 були класифіковані вірно із 100% впевненістю. Потім, згідно з тим, що було розкрито вище у цьому винаході та як показано на Фіг.15, ковзне вікно було лінійно переміщене вперед по відношенню до водонафтового контакту, з метою виявлення газової шапки.

У прикладі, що розглядається, також існували одержані у минулому фактичні дані щодо свердловин, про які було відомо, що вони розташовані в межах або за межами газової шапки. Отже дані були оброблені знову із врахуванням цих апіорних відомостей, і одержані результати були ідентичні тим, про які йшлося вище. Таким чином, передбачається, що додана формула винаходу, яка розкриває систему, спосіб та процес виявлення та оконтурювання вуглеводневих вуглецевих скупчень безпосередньо з сейсмічних даних, охоплює і такі умови, коли наявні апіорні відомості, і такі, коли подібних відомостей немає.

Після проведення навчання нейронної мережі оцінка усіх загальних глибинних точок, одержаних сейсморозвідкою, здійснюється як викладено нижче, що також є ще одним і, до того ж, новим способом внутрішнього підтвердження вірності аналізу, тобто визначення ступеня точності оконтурювання за допомогою системи, способу та процесу, що розкриваються у цьому винаході. Кожна траса загальної глибинної точки, що має бути оцінена як «In» або «Out», подається на нейронну мережу. Тобто, кожна траса множиться на ваговий коефіцієнт для одержання її чисельного показника в інтервалі від 0 до 1. Дуже рідко (або навіть ніколи) ці чисельні показники можуть дорівнювати точно 1 або точно 0. Отже, необхідно визначити, у якій точці між 0 та 1 загальна глибинна точка оцінюється як «In» або як «Out». Чисельні показники усіх трас даної загальної глибинної точки усереднюються для одержання чисельного показника загальної глибинної точки, яка знаходиться в інтервалі між 0 та 1. Коли загальні глибинні точки, що класифікуються як «In», чітко відрізняються від точок, які класифікуються як «Out», усі чисельні показники для загальних глибинних точок, які класифікуються як «In», більші за 0,5, а усі чисельні показники для загальних глибинних точок, які класифікуються як «Out», менші або рівні 0,5. Якщо існують які-небудь апіорні відомості, одержані зі свердловин, то точки в чисельних показниках загальних глибинних точок, які вірно відрізняють безсумнівно «In» та безсумнівно «Out», можуть бути визначені безпосередньо з відомих класифікацій загальних глибинних точок. Крім того, визначаючи кількість загальних глибинних точок, що знаходяться між тими точками, які безсумнівно класифікуються як «In» та тими точками, які безсумнівно класифікуються як «Out», можна визначити ступінь точності, який досягнутий даним передбаченням або даною класифікацією, шляхом застосування до відомих даних описаного вище способу.

Ще однією метою цього винаходу є розкриття нового способу визначення ступеня точності, досягнутого даним прогнозом або даною класифікацією, якщо немає апіорних відомостей для визначення такої точності. Після виявлення та класифікації вуглеводневого скупчення з використанням системи і способу, викладених вище, будуються, навчаються, перевіряються та класифікуються додаткові нейронні мережі з використанням тих загальних глибинних точок, які не були задіяні у первинній нейронній мережі, за допомогою якої одержувалася класифікація. Навчальні та тестові набори даних таких нейронних мереж складаються з загальних глибинних точок, що мають високі та низькі чисельні показники за первинною класифікацією, за допомогою якої виявлялося вуглеводневе скупчення. Потім сума загальних глибинних точок, для яких одержані несуперечливі чисельні показники «In» та несуперечливі чисельні показники «Out», ділиться на загальну кількість загальних глибинних точок для визначення точності прогнозу або класифікації. Стандартні статистичні методи, добре відомі спеціалістам даної галузі, можуть бути застосовані без жодних змін для визначення точності у тому випадку, коли наявні апіорні відомості.

Нарешті, ще однією новою метою цього винаходу є забезпечення системи, способу та процесу для моделювання вуглеводневих колекторів з використанням нейронних мереж. Після того як вуглеводневий колектор був оконтурований, той же самий набір змінних збірної точки сейсмічних трас та амплітуд, який використовувався для оконтурювання, розширений даними про сумарний видобуток, забійний тиск та продуктивність окремих свердловин, може застосовуватися протягом усього періоду експлуатації колектора для прогнозування рівнів видобутку на відповідних бурових ділянках. Змінна сумарного видобутку складається

з сумарного видобутку з колектора до моменту завершення буріння навчальної або запроєктованої свердловини. Змінна забійного тиску - це середній забійний тиск по всій площині колектора на момент завершення навчальної або запроєктованої свердловини. Змінна прогнозованого рівня видобутку - це видобуток з навчальної або запроєктованої свердловини протягом певного періоду часу після завершення її буріння, де несуперечність даних є важливішою за обрану величину періоду. Змінні, що використовуються додатково до змінних збірної точки сейсмічних трас та амплітуд, задаються для кожної з трас найближчих до свердловини загальних глибинних точок. Дані, одержані з останніх існуючих свердловин, не використовуються у навчальних наборах, а залишаються для тестових наборів. Навчання нейронних мереж продовжується доти, доки дисперсія на тестовому наборі даних не досягає мінімуму. Цей винахід припускає, що система, спосіб або процес для моделювання вуглеводневих колекторів можуть використовуватися з чотиримірними даними сейсморозвідки. Відповідно, передбачається, що додана формула винаходу охоплює усі такі варіанти його застосування, які відповідають справжній суті та обсягу даного винаходу.

Даний винахід припускає, що в інших варіантах використання нейронних мереж спеціалісти знайдуть варіанти застосування, інші ніж оконтурювання просторово залежних об'єктів, для способів, розкритих як способи визначення оптимальної кількості вузлів, оптимальної активаційної функції, включення у процес часткових відомостей або інтуїтивних здогадок щодо того, коли зупинити процес навчання тощо. Відповідно, передбачається, що додана формула винаходу охоплює усі такі варіанти застосування, які відповідають справжній суті та обсягу даного винаходу.

Конкретні приклади та варіанти втілення винаходу

Вище був розглянутий оптимальний варіант функціонування даного винаходу. У цьому розділі розглядаються оптимальні структури (архітектури) цього винаходу. Проте, треба розуміти, що модулярна структура (архітектура) даного винаходу також розглядалася вище у зв'язку з функціонуванням даного винаходу. Таким чином, певні частини структури даного винаходу по своїй суті були розглянуті у зв'язку з тим, що викладалося вище. Хоча існує багато різних типів штучних нейронних мереж, найбільш поширеними є штучні нейронні мережі зворотного розповсюдження помилок навчання та радіальної базисної функції (RBF/radial basis function/). Обидві ці архітектури нейронних мереж, так само як і мережі інших архітектур, можуть застосовуватися у способі, системі та процесі, які розкриваються у цьому винаході. Проте, описані вище ілюстративні приклади втілення даного винаходу базувалися на моделі зворотного розповсюдження помилок навчання.

Оптимальний варіант втілення даного винаходу включає одну або декілька комп'ютерних програмних систем. У цьому контексті, комп'ютерна програмна система - це сукупність однієї або декількох діючих комп'ютерних програм та однієї або декількох областей пам'яті, наприклад, оперативної пам'яті або пам'яті на диску. У загальних рисах, комп'ютерну програмну систему слід розуміти як повне функціональне програмне втілення функції, яке може бути додане до існуючої комп'ютерної системи для забезпечення нової функції цієї системи.

Отже, комп'ютерну програмну систему слід розуміти як програмне втілення функції, яке може бути скомпонованим як певна багатопланова архітектура, створюючи комп'ютерну систему, що забезпечує нову функціональність. Також, у загальному випадку існує чітке визначення інтерфейсу, який забезпечується однією програмною системою для зв'язку з іншою програмною системою. В контексті даного винаходу слід розуміти, що визначення границь між програмними системами є типовим для оптимального варіанту втілення винаходу. Проте, можливі втілення даного винаходу з використанням будь-яких інших комбінацій або розділень комп'ютерних програмних систем.

Слід розуміти, що нейронні мережі, для потреб використання у даному винаході, можуть бути втілені будь-яким чином. Наприклад, оптимальним варіантом є використання програмного варіанту втілення нейронної мережі. Проте, слід розуміти, що у даному винаході може використовуватися будь-яка форма втілення нейронних мереж, у тому числі - фізична аналогова та цифрова форми. Конкретніше, як описано нижче, нейронна мережа може бути втілена як програмний модуль комп'ютерної системи. Крім того, нейронна мережа у розумінні цього винаходу може бути втілена на одній комп'ютерній системі у процесі навчання і на іншій - в операційному режимі. Таким чином, комп'ютер нейронного типу з використанням паралельної обробки даних може застосовуватися на стадії процесу навчання, яка потребує багато комп'ютерних обчислень, а після адаптації значень вагових коефіцієнтів нейронної мережі ці вагові коефіцієнти та сама мережа можуть бути втілені на ряді інших обчислювальних пристроїв для генерування необхідних класифікацій з використанням необхідних операційних наборів даних. Аналогічно нейронні мережі можуть проходити процес навчання на одному процесорі, а потім в операційному режимі розподілятися між рядом паралельних процесорів.

У тому, що стосується даного винаходу, слід розуміти, що програмні та апаратні комп'ютерні варіанти його втілення є тільки одним можливим шляхом втілення різних елементів систем і способів. Як зазначалося вище, аналогова мережа може бути втілена в аналоговій або цифровій формі. Щодо етапів способу, описаних вище у зв'язку з функціонуванням систем, описаних у цьому розділі, слід розуміти, що такі операції, як обчислення або визначення (які передбачають використання цифрового комп'ютера), можуть також проводитися на аналогових еквівалентах або іншими методами.

У варіанті даного винаходу, процес навчання нейронної мережі може втілюватися у формі єдиної комп'ютерної програмної системи. Така єдина комп'ютерна програмна система може постачатися для її інсталяції на комп'ютері з метою забезпечення функцій згідно з даним винаходом. У іншому варіанті, функція (або програма) конфігурації нейронної мережі може також включатися до такої комп'ютерної програмної системи. Модуль конфігурації нейронної мережі може сполучатися у двонаправленій конфігурації з нейронною мережею. Модуль конфігурації нейронної мережі використовується користувачем (розробником) для створення конфігурації та контролю нейронної мережі так, як розглядалося вище у зв'язку з етапами та модулем, або так, як розглядатиметься нижче у зв'язку з інтерфейсом користувача. У продажу є ряд програмних пакетів, які включають нейронні мережі, що функціонують таким чином - наприклад, «Enterprise

Miner», розроблена «SAS Institute, Inc.», та BDS (Business Discovery Solutions /рішення для наукових відкриттів/), розроблена IBM Corporation у Армонку, Нью-Йорк.

Нейронна мережа містить модель нейронної мережі. Як зазначалося вище, даний винахід передбачає усі існуючі тепер та можливі у майбутньому розробки моделей та архітектур нейронної мережі. Модель нейронної мережі може включати варіанти повного зв'язування або повної відсутності зворотного зв'язку. Все це - просто приклади. Інші варіанти або архітектури моделі нейронної мережі також передбачаються даним винаходом.

Нейронна мережа має доступ до вхідних даних та до комірок, у яких може зберігати вихідні дані і дані про помилки. В одному з варіантів втілення даного винаходу використовується такий підхід, коли дані не зберігаються нейронною мережею. Замість того, нейронна мережа зберігає показники даних, які показують, де знаходяться місця збереження даних (тобто області робочої пам'яті) в окремих комп'ютерних програмних системах. Такі показники, що також називаються специфікаціями даних, можуть мати різні форми і можуть використовуватися для даних, що застосовуються для ряду різних потреб. Наприклад, можуть бути визначені показники вхідних даних та вихідних даних. Показник може використовувати або може вказувати на конкретне джерело одержання даних, конкретний тип даних та показник елементів даних. Нейронна мережа також має функцію зчитування збережених даних з пам'яті та функцію збереження даних. Прикладами таких функцій є програми, які можна викликати, доступ до диску та доступ до мережі. Це - просто приклади варіантів функцій зчитування з пам'яті та збереження даних. Оптимальним способом є використання нейронною мережею даних, одержаних за допомогою певного сенсорного процесу зчитування інформації. Дані з бази даних можуть зчитуватися самою нейронною мережею, або інший модуль може подавати дані до областей, визначених показниками нейронної мережі.

Як було розглянуто вище, нейронну мережу також необхідно навчати. Як зазначалося раніше, будь-який існуючий зараз або розроблений у майбутньому спосіб навчання передбачається даним винаходом. Спосіб навчання може також деякою мірою диктуватися архітектурою тієї моделі нейронної мережі, яка використовується. Прикладами варіантів способів навчання є зворотне розповсюдження помилки, узагальнена дельта та спадання градієнту; всі ці способи добре відомі спеціалістам.

Нейронна мережа вимагає знання типу даних, які задаються. Це особливо важливо, оскільки мережа може використовувати більше одного типу даних. Нарешті, задається показник елементів даних. Таким чином, видно, що нейронна мережа може бути побудована так, щоб одержувати бажані вхідні дані або видавати вихідні дані будь-якими бажаними засобами. В оптимальному варіанті втілення цього винаходу, це все досягається за допомогою вибору опцій меню користувачем (розробником) з використанням програмно реалізованої системи на основі комп'ютера. У даному винаході може застосовуватися інтерфейс користувача на основі шаблонів і меню, який дозволяє встановлювати та змінювати конфігурацію даного винаходу і оперувати системою. Такий підхід робить даний винахід дуже зручним для користувача. Також усувається необхідність у тому, щоби користувач сам займався комп'ютерним програмуванням, оскільки функції встановлення або зміни конфігурації та оперування системою здійснюються у форматі шаблонів та меню і не вимагають фактичних знань або навичок програмування. Є декілька загальнодоступних засобів для розробки нейронних мереж. Наприклад, «Enterprise Miner», розроблена «SAS Institute, Inc.», та «Intelligent Miner» (IM), розроблена IBM, забезпечують доступ до ряду різновидів нейронних мереж (включаючи мережі зі зворотним розповсюдженням помилки) за допомогою графічного інтерфейсу користувача (GUI /graphical user interface/), а також прикладного програмного інтерфейсу (API /application programmer's interface/), що дозволяє вбудовувати мережу до більшої системи. Інтерфейс GUI з пакету утиліт нейронних мереж (NMU /Neural Network Utilities/) працює на машинах з елементною базою Intel, що використовують системи OS/2 або DOS/Windows, та на машинах типу RISC/6000 з використанням AIX. Інтерфейс API допускає не тільки перелічені вище середовища, а також і ряд комп'ютерних систем, включаючи VM/CMS та OS/400. Передбачаються також і інші комп'ютерні системи, такі як різні варіанти Windows. До існуючих апаратних засобів, які дозволяють поліпшити навчання нейронних мереж та характеристики, пов'язані з тривалістю обчислювань, відноситься ШМ Wizard - карта, яка вставляється до шин стандарту MCA. До інших фірм, що продають аналогічні програмні та/або апаратні засоби, належать «Neuralware», «Nestor» та «Hecht-Nielsen Co.».

Альтернативні варіанти та заключні положення

Хоча цей винахід описаний у контексті використання сейсмічних даних для оконтурювання вуглеводневих скупчень із сейсмічних даних, цей винахід не обмежується зазначеним конкретним варіантом його застосування. Цей винахід може знайти використання у ряді галузей, включаючи, без обмеження переліченим: метеорологічні прогнози за даними радіометрів, аналіз аеромагнітних профілів, оконтурювання астрономічних кластерів за даними радіотелескопів, оконтурювання об'єктів за відображеними сигналами радарів або гідролокаторів, або за інфрачервоними відображеними сигналами тощо.

Хоча цей винахід докладно описаний тут у зв'язку з певними оптимальними варіантами його втілення, спеціалісти галузі зможуть вносити до них певні зміни та доповнення. Відповідно, передбачається, що додана формула винаходу охоплює усі такі зміни та доповнення, які відповідають справжній суті та обсягу цього винаходу.




Fig. 1

Fig. 2


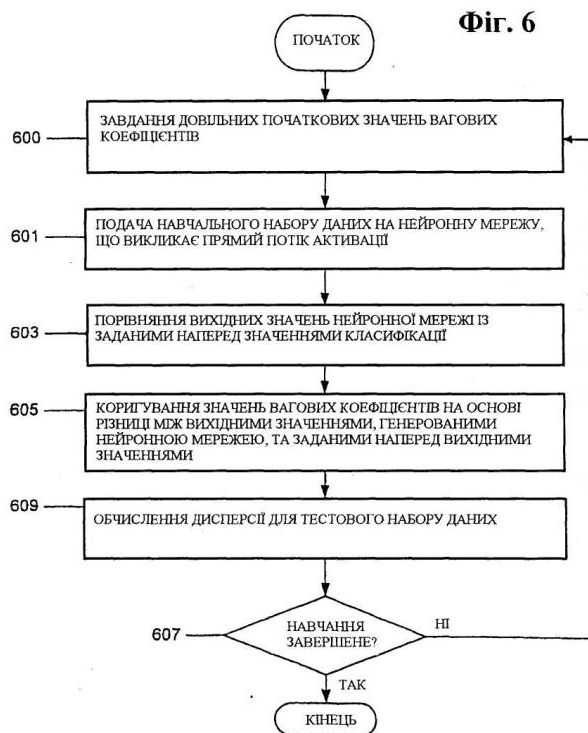




Fig. 3






Fig. 8




Fig. 9

