



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2019-0119691
(43) 공개일자 2019년10월23일

(51) 국제특허분류(Int. Cl.)
G06Q 40/06 (2012.01) G06Q 10/04 (2012.01)
G06Q 40/04 (2012.01)
(52) CPC특허분류
G06Q 40/06 (2013.01)
G06Q 10/04 (2013.01)
(21) 출원번호 10-2018-0042555
(22) 출원일자 2018년04월12일
심사청구일자 2018년04월12일

(71) 출원인
동국대학교 산학협력단
서울특별시 중구 필동로1길 30 내 (필동3가, 동국대학교)
충남대학교산학협력단
대전광역시 유성구 대학로 99 (궁동, 충남대학교)
(72) 발명자
손영두
서울특별시 중구 필동로1길 30 동국대학교 원흥관 435호
이윤희
대전광역시 유성구 대학로 1(봉명동)
(74) 대리인
강경돈

전체 청구항 수 : 총 6 항


(54) 발명의 명칭 무차익 옵션 가격 예측 방법

(57) 요약

주식 시장을 표현하는 모형으로서 무차익 옵션 가격 예측에 사용될 모수 모형(parametric model) 및 해당 모수 모형에 따라 학습될 기계 학습 모델(neural network model)을 선택하는 단계; 주식 시장에서 수집된 옵션의 실제 거래 데이터를 이용함으로써 상기 모수 모형이 옵션 거래에 관한 현실의 주식 시장을 반영할 수 있게 하는 모수

(뒷면에 계속)

대표도 - 도1



(parameter)를 추정하는 단계; 가격 예측이 필요한 옵션 만기의 최대값 및 최소값, 옵션 가격대의 최대값 및 최소값이 결정된 경우, 상기 옵션 만기 및 상기 옵션 가격대의 각각의 최대값과 최소값 사이의 2차원 격자점들을 생성하고, 상기 모수 추정이 완료된 모수 모형에서의 무차익 옵션 가격 결정 방법에 따라 상기 2차원 격자점들에 각각 상응하는 가상의 옵션 데이터를 생성하는 단계; 및 상기 가상 옵션 데이터 및 상기 실제 거래 데이터를 이용하여 상기 선택된 기계 학습 모델을 학습시키고, 학습된 기계 학습 모델을 이용하여 신규 입력 데이터에 관한 무차익 옵션 가격을 예측하는 단계를 포함하는 무차익 옵션 가격 예측 방법이 제공된다.

(52) CPC특허분류

G06Q 40/04 (2013.01)

명세서

청구범위

청구항 1

무차익 옵션 가격 예측을 위한 컴퓨터 구현 방법으로서,
주식 시장을 표현하는 모형으로서 무차익 옵션 가격 예측에 사용될 모수 모형(parametric model) 및 해당 모수 모형에 따라 학습될 기계 학습 모델(neural network model)을 선택하는 단계;
주식 시장에서 수집된 옵션의 실제 거래 데이터를 이용함으로써 상기 모수 모형이 옵션 거래에 관한 현실의 주식 시장을 반영할 수 있게 하는 모수(parameter)를 추정하는 단계;
가격 예측이 필요한 옵션 만기의 최대값 및 최소값, 옵션 가격대의 최대값 및 최소값이 결정된 경우, 상기 옵션 만기 및 상기 옵션 가격대의 각각의 최대값과 최소값 사이의 2차원 격자점들을 생성하고, 상기 모수 추정이 완료된 모수 모형에서의 무차익 옵션 가격 결정 방법에 따라 상기 2차원 격자점들에 각각 상응하는 가상의 옵션 데이터를 생성하는 단계; 및
상기 가상 옵션 데이터 및 상기 실제 거래 데이터를 이용하여 상기 선택된 기계 학습 모델을 학습시키고, 학습된 기계 학습 모델을 이용하여 신규 입력 데이터에 관한 무차익 옵션 가격을 예측하는 단계
를 포함하는 무차익 옵션 가격 예측 방법.

청구항 2

제1항에 있어서,
상기 모수를 추정하는 단계는,
해당 모수 모형의 무차익 옵션 가격 결정 방법에 따른 옵션 가격 예측치와 상기 실제 거래 데이터에 따른 옵션 가격 간의 에러(error)가 최소화되도록 하는 모수로 추정되는 것을 특징으로 하는, 무차익 옵션 가격 예측 방법.

청구항 3

제2항에 있어서,
상기 모수를 추정하는 단계는, 하기 수학적 식 1에 의해 실행되는 것을 특징으로 하는, 무차익 옵션 가격 예측 방법.

[수학적 식 1]

$$\hat{\lambda} = \operatorname{argmin}_{\lambda} \sum_k \|C(\mathbf{x}_k, \lambda) - y_k\|^2$$

여기서, $C(\mathbf{x}, \lambda)$ 는 해당 모수 모형에 따라 선택된 무차익 옵션 가격 결정 방법을 나타내고, 상기 수집된 실제 거래 데이터를 $\mathcal{D} = \{\mathbf{x}_k, y_k\}_{k=1}^N$ 라 할 때 $\mathbf{x}_k$ 는 실제 주식 시장에서 거래된 옵션의 만기와 가격대를 나타내고 y_k 는 실제 주식 시장에서 거래된 옵션의 가격을 나타내며, λ 는 해당 모수 모형에서의 모수를 나타내고 $\hat{\lambda}$ 는 추정된 모수를 나타냄.

청구항 4

제3항에 있어서,

상기 가상 옵션 데이터 및 상기 실제 거래 데이터를 이용하여 상기 기계 학습 모델을 학습시킴에 있어서, 하기의 수학적 2의 비용 함수에 따른 비용(ε)이 최소화될 수 있도록 뉴럴 네트워크 모델을 구축하는 것을 특징으로 하는, 무차익 옵션 가격 예측 방법.

[수학적 2]

$$\varepsilon = \frac{1}{2}(\sum_{k=1}^N \eta_1 \|f(\mathbf{x}_k) - y_k\|^2 + \sum_{i=1}^{\tilde{N}} \eta_2 \|f(\tilde{\mathbf{x}}_i) - \tilde{y}_i\|^2)$$

여기서, $\tilde{\mathbf{x}}_i$ 는 생성된 가상 옵션 데이터의 만기 및 가격대를 나타내고, $\tilde{y}_i$ 는 생성된 가상 옵션 데이터에 따른 옵션 가격을 나타내며, $f(\mathbf{x}_k)$ 는 실제 거래 데이터를 입력으로 한 상기 기계 학습 모델에 따른 예측 옵션 가격을 나타내고, $f(\tilde{\mathbf{x}}_i)$ 는 가상 옵션 데이터를 입력으로 한 상기 기계 학습 모델에 따른 예측 옵션 가격을 나타내며, η_1 및 η_2 는 각각에 적용된 가중치를 나타냄.

청구항 5

제4항에 있어서,

상기 수학적 2의 비용 함수에 따른 비용이 최소화되도록 하는 상기 가중치들을 결정함에 있어서 역전파(backpropagation) 알고리즘을 이용하는 것을 특징으로 하는, 무차익 옵션 가격 예측 방법.

청구항 6

제1항 내지 제5항 중 어느 한 항에 따른 무차익 옵션 가격 예측 방법이 기록되며 컴퓨터로 읽을 수 있는 기록 매체 제품.

발명의 설명

기술 분야

[0001] 본 발명은 가상 생성 데이터를 이용한 기계 학습의 무차익 옵션 가격 예측 방법에 관한 것이다.

배경 기술

[0002] 옵션은 가장 널리 거래되는 금융 파생상품의 하나로, 리스크 헷징, 투기 등 다양한 목적에 활용될 수 있기 때문에 많은 관심을 받아왔다. 이러한 옵션의 사용을 위하여 투자자들은 옵션의 적절한 가격을 알아야 할 필요가 있었고, 이에 따라 Black과 Scholes(1973)가 처음으로 옵션의 정당한 가격의 수리적인 옵션의 가격을 제안하였다.

[0003] 그러나 Black과 Scholes의 옵션 가격 결정 방법은 주식의 가격이 기하 브라운 운동을 따른다는 가정 하에 개발된 방법이고, 이는 현실의 주식시장에서 관찰되는 스마일 현상, 팻테일 현상 등을 반영하지 못하고 있다. 이에 따라, 이러한 현상들을 설명할 수 있는 여러 확률 프로세스들이 주식 시장의 움직임을 설명하기 위해 사용되었다. 이러한 확률 프로세스들은 모수에 따라 그 함수가 변화하기 때문에 모수 모형(parametric model)이라고 일컬어진다.

[0004] 금융 시장에서 자산의 가격을 결정하는 주요 원리 중 하나는 무차익 이론이다. 무차익 이론이란 구성하는 데 비용이 들지 않으나, 100%의 확률로 수익을 내는 포트폴리오는 존재하지 않는다는 것이다. 쉬운 예시로 두 주식 시장에 동시에 상장되어 있는 어떠한 주식의 가격을 생각해보자. 만일 이 주식의 가격이 두 주식시장에서 다르다면, 투자자는 가격이 더 싼 시장에서 주식을 구매한 후 다른 시장에서 팔면 본인의 가진 포트폴리오에는 변화

가 없으며 금전적인 이득을 얻을 수 있다. 이러한 거래의 형태를 차익 거래, 포트폴리오를 차익 포트폴리오라고 하며, 일반적으로 차익 거래의 기회는 발견되는 즉시 사라지는 것으로 알려져 있다.

[0005] 1990년대 중반 이후, 많은 기계학습 및 인공지능 방법론들이 시장에서 거래되고 있는 옵션의 가격을 예측하기 위하여 사용되었으며, 좋은 성과를 현재까지도 거두고 있다. 그러나 이러한 기계학습 알고리즘들에 의하여 예측된 가격은 시장 가격 대비 정확도는 높으나 무차익 가격은 아니며, 기존 금융 이론과 모순되는 결과로 나타난다. 아직까지 기계학습 알고리즘 기반으로 무차익 가격을 제공하는 방법은 존재하지 않는다.

발명의 내용

해결하려는 과제

[0006] 본 발명은 무차익 옵션 가격 예측을 제공하는 기계 학습 방법을 제공하기 위한 것이다. 이를 위하여 모수 모형을 통하여 가상의 무차익 옵션 가격 데이터를 다량으로 생성하고, 이에 적절한 가중치를 주어 시장에서 얻어진 데이터와 함께 기계학습 모형의 학습 데이터로 활용하며, 이렇게 학습된 기계학습 모형은 무차익 가격과 매우 흡사하면서도 높은 정확도의 옵션 가격을 예측할 수 있도록 한다.

과제의 해결 수단

[0007] 본 발명의 일 측면에 따르면, 무차익 옵션 가격 예측을 위한 컴퓨터 구현 방법으로서, 주식 시장을 표현하는 모형으로서 무차익 옵션 가격 예측에 사용될 모수 모형(parametric model) 및 해당 모수 모형에 따라 학습된 기계학습 모델(neural network model)을 선택하는 단계; 주식 시장에서 수집된 옵션의 실제 거래 데이터를 이용함으로써 상기 모수 모형이 옵션 거래에 관한 현실의 주식 시장을 반영할 수 있게 하는 모수(parameter)를 추정하는 단계; 가격 예측이 필요한 옵션 만기의 최대값 및 최소값, 옵션 가격대의 최대값 및 최소값이 결정된 경우, 상기 옵션 만기 및 상기 옵션 가격대의 각각의 최대값과 최소값 사이의 2차원 격자점들을 생성하고, 상기 모수 추정이 완료된 모수 모형에서의 무차익 옵션 가격 결정 방법에 따라 상기 2차원 격자점들에 각각 상응하는 가상의 옵션 데이터를 생성하는 단계; 및 상기 가상 옵션 데이터 및 상기 실제 거래 데이터를 이용하여 상기 선택된 기계학습 모델을 학습시키고, 학습된 기계학습 모델을 이용하여 신규 입력 데이터에 관한 무차익 옵션 가격을 예측하는 단계를 포함하는 무차익 옵션 가격 예측 방법이 제공된다.

[0008] 본 발명의 실시예에서, 상기 모수를 추정하는 단계는,

[0009] 해당 모수 모형의 무차익 옵션 가격 결정 방법에 따른 옵션 가격 예측치와 상기 실제 거래 데이터에 따른 옵션 가격 간의 에러(error)가 최소화되도록 하는 모수로 추정될 수 있다.

[0010] 이를 위해, 상기 모수를 추정하는 단계는, 하기 수학식 1에 의해 실행될 수 있다.

[0011] [수학식 1]

$$\hat{\lambda} = \operatorname{argmin}_{\lambda} \sum_k \|C(\mathbf{x}_k, \lambda) - y_k\|^2$$

[0013] 여기서, $C(\mathbf{x}, \lambda)$ 는 해당 모수 모형에 따라 선택된 무차익 옵션 가격 결정 방법을 나타내고, 상기 수집된 실제 거래 데이터를 $\mathcal{D} = \{\mathbf{x}_k, y_k\}_{k=1}^N$ 라 할 때 $\mathbf{x}_k$ 는 실제 주식 시장에서 거래된 옵션의 만기와 가격대를 나타내고 y_k 는 실제 주식 시장에서 거래된 옵션의 가격을 나타내며, λ 는 해당 모수 모형에서의 모수를 나타내고 $\hat{\lambda}$ 는 추정된 모수를 나타냄.

[0014] 본 발명의 실시예에서, 상기 가상 옵션 데이터 및 상기 실제 거래 데이터를 이용하여 상기 기계 학습 모델을 학습시키는 단계는, 하기의 수학식 2의 비용 함수에 따른 비용(ε)이 최소화될 수 있도록 뉴럴 네트워크 모델을 구축하는 것일 수 있다.

[0015] [수학식 2]

$$\varepsilon = \frac{1}{2}(\sum_{k=1}^N \eta_1 \|f(\mathbf{x}_k) - y_k\|^2 + \sum_{i=1}^{\tilde{N}} \eta_2 \|f(\tilde{\mathbf{x}}_i) - \tilde{y}_i\|^2)$$

[0017] 여기서, $\tilde{\mathbf{x}}_i$ 는 생성된 가상 옵션 데이터의 만기 및 가격대를 나타내고, $\tilde{y}_i$ 는 생성된 가상 옵션 데이터에 따른 옵션 가격을 나타내며, $f(\mathbf{x}_k)$ 는 실제 거래 데이터를 입력으로 한 상기 기계 학습 모델에 따른 예측 옵션 가격을 나타내고, $f(\tilde{\mathbf{x}}_i)$ 는 가상 옵션 데이터를 입력으로 한 상기 기계 학습 모델에 따른 예측 옵션 가격을 나타내며, η_1 및 η_2 는 각각에 적용된 가중치를 나타냄.

[0018] 이때, 상기 수학식 2의 비용 함수에 따른 비용이 최소화되도록 하는 상기 가중치들을 결정함에 있어서 역전파(backpropagation) 알고리즘을 이용할 수 있다.

[0019] 본 발명의 다른 측면에 따르면, 상술한 바와 같은 무차익 옵션 가격 예측 방법이 기록되며 컴퓨터로 읽을 수 있는 기록 매체 제품이 제공될 수 있다.

발명의 효과

[0020] 현재 옵션 가격의 예측 방법은 크게 모수 모형 기반의 옵션 가격 예측과, 기계 학습을 이용한 예측 방법의 두 가지이다. 모수 모형 기반 옵션 가격 예측은 무차익 가격을 제공하여주나 실제 거래된 가격과 비교한 정확도가 상대적으로 낮다. 반면, 기계학습 기반 옵션 가격 예측은 높은 정확도의 옵션 가격을 제공하여주나, 제공된 옵션 가격들이 무차익 가격이 아니다. 따라서 본 발명의 실시예에서는 무차익 가격을 제공해주는 기계 학습 모형을 학습하여, 무차익성과 높은 정확도를 동시에 가지는 옵션 예측가격을 제공할 수 있고, 이에 따라 많은 투자자들에게 금융 이론을 따르며 정확한 가격을 제공해주어 개인의 용도에 맞게 옵션을 거래하는 데 도움을 줄 수 있다.

도면의 간단한 설명

[0021] 도 1은 본 발명의 실시예에 따른 무차익 옵션 가격 예측 방법에 관한 알고리즘을 설명하기 위한 플로우차트.

도 2는 옵션 가격대 및 옵션 만기를 이용한 2차원 격자 상에서 생성된 가상 옵션 데이터를 설명하기 위한 참조도면.

도 3은 종래 기술에 따른 방식과 본 발명의 실시예에 따른 방식 간의 효과 상의 차이를 비교 설명하기 위한 시뮬레이션 결과 그래프.

발명을 실시하기 위한 구체적인 내용

[0022] 본 발명은 다양한 변환을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 상세한 설명에 상세하게 설명하고자 한다. 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변환, 균등물 내지 대체물을 포함하는 것으로 이해되어

야 한다.

- [0023] 본 발명을 설명함에 있어서, 관련된 공지 기술에 대한 구체적인 설명이 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우 그 상세한 설명을 생략한다. 또한, 본 명세서의 설명 과정에서 이용되는 숫자(예를 들어, 제1, 제2 등)는 하나의 구성요소를 다른 구성요소와 구분하기 위한 식별기호에 불과하다.
- [0024] 또한, 명세서 전체에서, 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다. 또한, 명세서에 기재된 "부", "모듈" 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하나 이상의 하드웨어나 소프트웨어 또는 하드웨어 및 소프트웨어의 조합으로 구현될 수 있음을 의미한다.
- [0025] 도 1은 본 발명의 실시예에 따른 무차익 옵션 가격 예측 방법에 관한 알고리즘을 설명하기 위한 플로우차트이다. 또한 도 2는 옵션 가격대 및 옵션 만기를 이용한 2차원 격자 상에서 생성된 가상 옵션 데이터를 설명하기 위한 참조 도면이고, 도 3은 종래 기술에 따른 방식과 본 발명의 실시예에 따른 방식 간의 효과 상의 차이를 비교 설명하기 위한 시뮬레이션 결과 그래프이다. 이하, 첨부된 도면들을 참조하여 본 발명의 실시예를 상세히 설명한다.
- [0026] 본 발명은 주식 시장을 잘 표현할 수 있는 모수 모형으로부터 가상의 무차익 옵션 가격 데이터를 생성하여 이를 기계 학습 모델의 학습을 위한 입력 데이터로서 시장에서 실제 거래된 옵션 거래 데이터와 함께 사용하는 방식을 채용한다. 이에 관한 보다 구체적인 프로세스는 다음과 같다.
- [0027] 도 1을 참조할 때, 본 발명의 실시예에 따른 무차익 옵션 가격 예측을 위한 컴퓨터 구현 방법은, 알고리즘 초기화 단계로서 주식 시장을 잘 표현해줄 수 있는 모형으로서 무차익 옵션 가격 예측에 사용될 모수 모형(parametric model)과 해당 모수 모형에 따라 학습될 기계 학습 모델(neural network model)을 선택하고, 현실의 주식 시장에서 거래됐던 시장 데이터(즉, 실제 옵션 거래 데이터)를 수집한다[S110 참조]. 이때 사용 가능한 모수 모형의 전형적인 예로는 트리 모델(tree model), 몬테 카를로 방식(Monte Carlo method), 유한 차분법(finite difference method) 등이 있을 수 있으며, 이외에도 다양한 모수 모형이 선택될 수 있다.
- [0028] 위와 같이 모수 모형이 선택되면, 주식 시장에서 수집된 옵션의 실제 거래 데이터를 이용함으로써 상기 모수 모형이 옵션 거래에 관한 현실의 주식 시장을 반영할 수 있게 하는 모수(parameter)를 추정한다[S120 및 S125 참조].
- [0029] 이때, 모수 추정에는 다음과 같은 방법이 이용될 수 있다. 즉, 해당 모수 모형의 무차익 옵션 가격 결정 방법에 따른 옵션 가격 예측치와 상기 실제 거래 데이터에 따른 옵션 가격 간의 에러(error)가 최소화되도록 하는 모수로 추정될 수 있다. 이를 위해 하기 수학적 1이 이용될 수 있다.

수학적 1

[0030]
$$\hat{\lambda} = \operatorname{argmin}_{\lambda} \sum_k \|C(\mathbf{x}_k, \lambda) - y_k\|^2$$

[0031] 여기서, $C(\mathbf{x}, \lambda)$ 는 해당 모수 모형에 따라 선택된 무차익 옵션 가격 결정 방법을 나타내고, 상기 수집된 실제 거래 데이터를 $\mathcal{D} = \{\mathbf{x}_k, y_k\}_{k=1}^N$ 라 할 때 $\mathbf{x}_k$ 는 실제 주식 시장에서 거래된 옵션의 만기와 가격대를 나타내고 y_k 는 실제 주식 시장에서 거래된 옵션의 가격을 나타내며, λ 는 해당 모수 모형에서의 모수를 나타내고 $\hat{\lambda}$ 는 추정된 모수를 나타낸다.

[0032] 다시 도 1을 참조하면, 가격 예측이 필요한 옵션 만기의 최대값 및 최소값, 옵션 가격대의 최대값 및 최소값을 결정하고, 상기 옵션 만기 및 상기 옵션 가격대의 각각의 최대값과 최소값 사이의 2차원 격자점들(즉, 2차원 상의 격자 좌표들)을 생성한다[S130 및 S135 참조].

[0033] 이때, 상술한 도 1의 S120 및 S125 단계와 도 1의 S130 및 S135 단계는 선후 관계 없이 함께 병행하여 또는 동시에 수행될 수 있다.

[0034] 상술한 바와 같이, 선택된 모수 모형에서 모수 추정이 완료되고 또한 2차원 격자점들이 생성되면, 상기 모수 추정이 완료된 모수 모형에서의 무차익 옵션 가격 결정 방법에 따라 상기 2차원 격자점들에 각각 상응하는 가상의 옵션 데이터를 생성한다[S140 참조]. 이때 2차원 격자점들 마다에 가상의 옵션 데이터를 맵핑한 예가 도 2를 통해 도시되고 있다. 이러한 옵션 데이터들은 모수 모형에서 생성되었기 때문에 무차익 가격을 갖게 된다.

[0035] 상술한 바와 같이 가상의 옵션 데이터가 생성되면, 그와 같이 생성된 가상 옵션 데이터 및 상기 실제 거래 데이터를 함께 이용하여 앞서 선택된 기계 학습 모델을 학습시킨다[S150 참조]. 이때, 기계 학습 모델의 학습에는 다음과 같은 방식이 적용될 수 있다.

[0036] 즉, 본 발명의 실시예에서, 상기 가상 옵션 데이터 및 상기 실제 거래 데이터를 이용하여 상기 기계 학습 모델을 학습시키는 단계는, 하기의 수학적 2의 비용 함수에 따른 비용(ϵ)이 최소화될 수 있도록 뉴럴 네트워크 모델을 구축하는 것일 수 있다.

수학적 2

$$\epsilon = \frac{1}{2} (\sum_{k=1}^N \eta_1 \|f(\mathbf{x}_k) - y_k\|^2 + \sum_{i=1}^{\tilde{N}} \eta_2 \|f(\tilde{\mathbf{x}}_i) - \tilde{y}_i\|^2)$$

[0038] 여기서, $\tilde{\mathbf{x}}_i$ 는 생성된 가상 옵션 데이터의 만기 및 가격대를 나타내고, $\tilde{y}_i$ 는 생성된 가상 옵션 데이터에 따른 옵션 가격을 나타내며, $f(\mathbf{x}_k)$ 는 실제 거래 데이터를 입력으로 한 상기 기계 학습 모델에 따른 예측 옵션 가격을 나타내고, $f(\tilde{\mathbf{x}}_i)$ 는 가상 옵션 데이터를 입력으로 한 상기 기계 학습 모델에 따른 예측 옵션 가격을 나타내며, η_1 및 η_2 는 각각에 적용된 가중치를 나타낸다.

[0039] 이때, 상기 수학적 2의 비용 함수에 따른 비용이 최소화되도록 하는 상기 가중치들을 결정하게 되면, 무차익 옵션 가격의 예측의 정확도를 높인 기계 학습 모델을 구축할 수 있다. 이때, 상기 비용 함수에 따른 비용이 최소화되도록 하는 가중치들을 찾아냄에 있어서는 역전파(backpropagation) 알고리즘을 이용할 수 있다.

[0040] 상술한 바에 따라 학습된 기계 학습 모델을 이용하면 향후 입력된 신규 입력 데이터에 대하여 정확도가 높으면서도 무차익 가격에 가까운 옵션 가격을 예측할 수 있게 된다.

[0041] 상술한 바에 따른 무차익 옵션 가격 예측 방법에 따르면, 종래 기술과 비교할 때 2가지 차별성을 갖게 된다. 첫째로는 무차익 가격의 가상 옵션 데이터를 시장 데이터와 함께 사용하여, 학습된 기계 학습 모델이 옵션 가격을 예측할 때 정확하면서도 무차익성을 가지는 가격을 예측하게 되는 것이다. 둘째로는 특정 가격대와 만기에 밀집되어 있는 시장데이터와 달리, 가상 데이터는 원하는 여러 가격대와 만기에 맞추어 만들 수 있기 때문에, 학습된 기계학습 모형이 기존에 시장에서 거래되지 않은 만기 및 가격대의 옵션에 대하여도 좋은 성능을 보이도록 해준다.

[0042] 도 3은 2012년 S&P100 American put 옵션에 적용한 결과로서, 빨간 선은 기존의 깊은 신경망을 사용하여 예측했을 때의 에러이며, 파란 색은 본 발명에서 제시된 방법으로 학습했을 때의 에러 값들이다. 이에 따를 때, 본 발명의 방식에 의할 때 에러 값들이 월등히 적은 것을 확인할 수 있다.

[0043] 상술한 본 발명의 실시예에 따른 무차익 옵션 가격 예측 방법은 컴퓨터로 읽을 수 있는 기록 매체에 컴퓨터가 읽을 수 있는 코드로서 구현되는 것이 가능하다. 컴퓨터가 읽을 수 있는 기록매체로는 컴퓨터 시스템에 의하여 해독될 수 있는 데이터가 저장된 모든 종류의 기록 매체를 포함한다. 예를 들어, ROM(Read Only Memory), RAM(Random Access Memory), 자기 테이프, 자기 디스크, 플래시 메모리, 광 데이터 저장장치 등이 있을 수 있다. 또한, 컴퓨터가 읽을 수 있는 기록매체는 컴퓨터 통신망으로 연결된 컴퓨터 시스템에 분산되어, 분산방식


으로 읽을 수 있는 코드로서 저장되고 실행될 수 있다.

[0044]


이상에서는 본 발명의 실시예를 참조하여 설명하였지만, 해당 기술 분야에서 통상의 지식을 가진 자라면 하기의 특허 청구의 범위에 기재된 본 발명의 사상 및 영역으로부터 벗어나지 않는 범위 내에서 본 발명을 다양하게 수정 및 변경시킬 수 있음을 쉽게 이해할 수 있을 것이다.

도면

도면1



도면2



도면3

